



**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**INSPEÇÃO AUTOMÁTICA DE CERÂMICAS LISAS VIA
ACUSTICA DIFUSA**

**DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL DE SANTA CATARINA
PARA OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA**

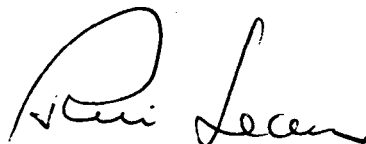
Eider Lúcio de Oliveira

FLORIANÓPOLIS, DEZEMBRO DE 1997

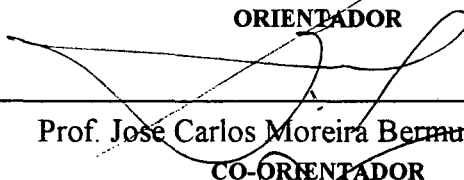
INSPEÇÃO AUTOMÁTICA DE CERÂMICAS LISAS VIA LÓGICA DIFUSA

CANDIDATO: EIDER LÚCIO DE OLIVEIRA

Esta dissertação foi julgada para obtenção do título de **MESTRE EM ENGENHARIA ELÉTRICA - ESPECIALIDADE ENGENHARIA ELÉTRICA** e aprovada em sua forma final pelo Curso de Pós-graduação.



Prof. Rui Seara, Dr. Ing.
ORIENTADOR



Prof. Jose Carlos Moreira Bermudez, Ph.D.
CO-ORIENTADOR

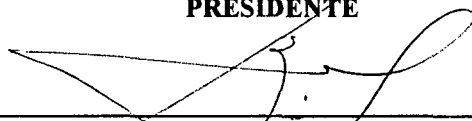


Prof. Adroaldo Raizer, Dr.
COORDENADOR DO CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA


BANCA EXAMINADORA:



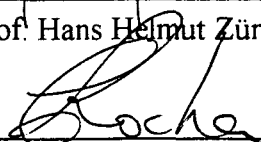
Prof. Rui Seara, Dr. Ing.
PRESIDENTE



Prof. José Carlos Moreira Bermudez, Ph.D.



Prof. Hans Helmut Zürn, Ph.D.



Prof. Carlos Aurélio Faria da Rocha, D. Sc.

À minha esposa Magali

e à minha filha Carolina

AGRADECIMENTOS

Quero deixar registrada minha sincera gratidão:

Aos meus pais pelo incentivo e carinho.

À CAPES pelo apoio financeiro, fundamental na realização deste trabalho.

Aos meus orientadores Prof. Rui Seara e Prof. José Carlos Moreira Bermudez pela valiosa orientação.

A todos os amigos do LINSE (Laboratório de Instrumentação Eletrônica da UFSC) pela ajuda cordial e bom humor perene. Em especial a Elton Luiz Fontão, Walter Antônio Gontijo, Orlando José Tobias, Guilherme Vall Teixeira, Evânio Ramos Nicoleit, César Zeferino, Ricardo Takase e Ana Isabela pelo companheirismo, apoio e confiança.

E a todos aqueles que de alguma forma colaboraram para realização deste trabalho o meu **muito obrigado**.

SUMÁRIO

LISTA DE FIGURAS.....	x
LISTA DE TABELAS.....	xiii
RESUMO	xv
ABSTRACT.....	xvi
CAPÍTULO 1 - INTRODUÇÃO	1
CAPÍTULO 2 - APRESENTAÇÃO DOS OBJETOS SOB ANÁLISE.....	7
2.1 Introdução.....	7
2.2 Processos de Decoração	7
2.3 Tipos de Defeitos nas Cerâmicas Lisas	9
2.3 Conclusões.....	13
CAPÍTULO 3 - LÓGICA DIFUSA	14
3.1 Introdução.....	14
3.2 Conceito de Lógica Difusa	14
3.3 Função de Pertinência	16
3.3.1 Características de uma Função de Pertinência	17
3.3.2 Tipos de Função de Pertinência.....	19

3.4 Variável Lingüística e Valor Lingüístico	20
3.5 Operações com Conjuntos Difusos	21
3.5.1 União	21
3.5.2 Interseção.....	22
3.5.3 Complemento.....	22
3.6 Propriedades dos Conjuntos Difusos.....	23
3.6.1 Comutatividade.....	23
3.6.2 Associatividade.....	23
3.6.3 Distributividade	23
3.6.4 Idempotência	23
3.6.5 Identidade	23
3.6.6 Transitividade	23
3.6.7 Involução	23
3.6.8 Lei de Morgan	24
3.6.9 Lei do Meio Excluído	24
3.7 Operações Algébricas com Conjuntos Difusos.....	24
3.7.1 Produto Cartesiano.....	24
3.7.2 Enésima Potência.....	24

3.7.3 Soma Algébrica.....	25
3.7.4 Produto Algébrico.....	25
3.7.5 Soma Limitada.....	25
3.7.6 Diferença Limitada	25
3.8 Sistema Difuso.....	27
3.8.1 Base de Dados	27
3.8.2 Fuzificação	29
3.8.3 Avaliação de Regras.....	29
3.8.4 Desfuzificação	31
3.8.4.1 Método do Centróide	32
3.8.4.1 Método das Barras Verticais (<i>Singletons</i>).....	33
CAPÍTULO 4 - PROCESSO DIFUSO NA CLASSIFICAÇÃO DE CERÂMICA	34
4.1 Introdução.....	34
4.2 Sistema de Inspeção Automático	35
4.3 Pré-processamento.....	36
4.3.1 Variáveis Lingüísticas	37
4.3.2 Treinamento.....	39
4.3.3 Funções de Pertinência	41

4.3.3.1 Curva Trapezoidal.....	41
4.3.3.2 Curva “S”.....	42
4.3.3.3 Curva Sigmóide	44
4.3.4 Ajuste das Curvas de Pertinência	45
4.4 Fuzificação	52
4.4.1 Fuzificação da Variável MANCHA	53
4.4.1.1 Dispersão de Mancha.....	55
4.4.1.2 Dispersão Limite.....	57
4.4.1.3 Fuzificação de Dispersão	60
4.4.1.4 Exemplo de Fuzificação da Variável Mancha.....	63
4.4.2 Fuzificação da Variável TONALIDADE.....	67
4.5 Desfuzificação	68
4.5.1 Processo de Desfuzificação Convencional	68
4.5.2 Processo de Desfuzificação Simplificado	72
CAPÍTULO 5 - RESULTADOS EXPERIMENTAIS	77
5.1 Introdução.....	77
5.2 Grupos de Treinamento.....	78
5.3 Parâmetros de Ajuste	79

5.4 Resultados	80
5.4.1 Resultados do Grupo I	80
5.4.2 Resultados do Grupo II	82
5.5 Análise dos Resultados	83
 CAPÍTULO 6 - CONCLUSÕES.....	85
 REFERÊNCIAS BIBLIOGRÁFICAS	87
 APÊNDICE A - ALGORITMO PARA A DETERMINAÇÃO DO <i>PIXEL</i>	
REPRESENTATIVO DE MANCHAS.....	91
A.1 Introdução.....	91
A.2 Variáveis de Entrada.....	91
A.3 Passos do Algoritmo.....	92
A.4 Simulação	95
 APÊNDICE B - AGRUPAMENTO DE MANCHAS	96
B.1 Introdução	96
B.2 Variáveis de Entrada	96
B.3 Passos do Algoritmo.....	97

LISTA DE FIGURAS

Fig. 1.1 - Lógica convencional e lógica difusa.....	4
Fig. 2.1 - Cerâmica lisa sem defeitos (Grupo I)	8
Fig. 2.2 - Cerâmica lisa com mancha (Grupo I)	9
Fig. 2.3 - Cerâmica lisa com manchas espalhadas (Grupo I)	10
Fig. 2.4 - Cerâmica lisa com tonalidade mais escura (Grupo I)	11
Fig. 2.5 - Cerâmica lisa com tonalidade normal (Grupo I)	11
Fig. 2.6 - Cerâmica de tonalidade escura sem defeitos (Grupo II).....	12
Fig. 2.7 - Cerâmica de tonalidade escura com manchas (Grupo II).....	12
Fig. 3.1 - Exemplos de função de pertinência	16
Fig. 3.2 - Centro, suporte e fronteiras de um conjunto difuso	17
Fig. 3.3 - Conjunto difuso normalizado e não-normalizado.....	18
Fig. 3.4 - Conjunto difuso convexo e não-convexo	18
Fig. 3.5 - Interseção de dois conjuntos difusos convexos.....	19
Fig. 3.6 - Curvas de pertinência triangular e trapezoidal	19
Fig. 3.7 - Curvas em “S” e sino.....	20
Fig. 3.8 - Variável lingüística TEMPERATURA e seus valores lingüísticos.....	21

Fig. 3.9 - Operações básicas com conjuntos difusos	22
Fig. 3.10 - Fluxo de dados de um sistema difuso	27
Fig. 3.11 - Funções de pertinência para o exemplo	28
Fig. 3.12 - Função de pertinência de saída com truncamento	31
Fig. 3.13 - Desfuzificação usando o método de barras verticais	33
Fig. 4.1 - Estrutura de um sistema de inspeção de cerâmicas automático	35
Fig. 4.2 - Parte da Matriz Intensidade de uma cerâmica lisa com mancha destacada.....	38
Fig. 4.3 - Fronteiras dos valores lingüísticos centrais.....	41
Fig. 4.4 - Curva de pertinência trapezoidal para valor lingüístico central.....	42
Fig. 4.5 - Funções “S” e π	43
Fig. 4.6 - Curvas sigmoidais com variação de k e d_c	44
Fig. 4.7 - Curvas sigmóides para valor lingüístico central	45
Fig. 4.8 - Curvas sigmóides para valores lingüísticos central e laterais	45
Fig. 4.9 - Variação na grau de pertinência de acordo com aumento do domínio da curva.....	46
Fig. 4.10 - Parâmetros usados no ajuste das curvas de pertinência.....	48
Fig. 4.11 - Curvas de pertinência “S” de mancha aceitável com variações de μ_a	48
Fig. 4.12 - Gráfico de pertinência para variável lingüística MANCHA.....	49
Fig. 4.13 - Gráfico de pertinência para variável lingüística TONALIDADE.....	49
Fig. 4.14 - Gráfico do erro nos pontos a_i , a_f e m_d em função do ajuste μ_a	51

Fig. 4.15 - Parte de uma <i>matriz-amostra</i> com mancha destacada e posição dos <i>pixels</i> (C/L: coluna/linha).....	54
Fig. 4.16 - Distribuição de manchas por uma circunferência para cálculo da dispersão limite global	58
Fig. 4.17 - Distribuição de manchas por uma circunferência para cálculo da dispersão limite local	60
Fig. 4.18 - Curvas de pertinência para dispersão de manchas (global e local).....	61
Fig. 4.19 - Peça cerâmica com presença de mancha escuras e claras	63
Fig. 4.20 - Curva de pertinência para dispersão das manchas escuras.....	64
Fig. 4.21 - Curva de pertinência para dispersão das manchas claras	65
Fig. 4.22 - Fuzificação da variável TONALIDADE.....	67
Fig. 4.23 - Curvas triangulares com as classes de saída A, B e C	70
Fig. 4.24 - Processo de desfuzificação usando centro de gravidade	71
Fig. 4.25 - Divisão do contradomínio em setores.....	72

LISTA DE TABELAS

Tabela 3.1 - Fuzificação das variáveis de entrada do exemplo	29
Tabela 3.2 - Valores de pertinência obtidos da Avaliação das Regras	31
Tabela 4.1 - Variáveis e valores lingüísticos	39
Tabela 4.2- Regras de inferência	69
Tabela 4.3 - Tabela de saída para processo de desfuzificação simplificado.....	74
Tabela 5.1 - Fronteiras de treinamento para o Grupo I.....	78
Tabela 5.2 - Fronteiras de treinamento para o Grupo II.....	79
Tabela 5.3 - Parâmetros de ajuste usados nas simulações.	79
Tabela 5.4 - Classificação usando curva trapezoidal (Boas: Grupo I)	80
Tabela 5.5- Classificação usando curva "S" (Boas: Grupo I)	80
Tabela 5.6 - Classificação usando curva sigmoidal (Boas: Grupo I).....	80
Tabela 5.7 - Classificação usando curva trapezoidal (Ruins: Grupo I)	81
Tabela 5.8 - Classificação usando curva "S" (Ruins: Grupo I)	81
Tabela 5.9 - Classificação usando curva sigmoidal (Ruins: Grupo I).....	81
Tabela 5.10 - Classificação usando curva trapezoidal (Boas: Grupo II)	82
Tabela 5.11 - Classificação usando curva "S" (Boas: Grupo II).....	82

Tabela 5.12 - Classificação usando curva sigmoidal (Boas: Grupo II).....	82
Tabela 5.13 - Classificação usando curva trapezoidal (Ruins: Grupo II)	83
Tabela 5.14 - Classificação usando curva "S" (Ruins: Grupo II).....	83
Tabela 5.15 - Classificação usando curva sigmoidal (Ruins: Grupo II).....	83

RESUMO

A lógica difusa tem tido uma aplicabilidade grande devido ao tratamento da incerteza por ela oferecido, levando a novos métodos de aquisição, representação e utilização do conhecimento. Na área de inspeção industrial, o interesse nesse tipo de sistema vem crescendo pois, na maioria das aplicações, as fronteiras das características dos objetos inspecionados não têm limites bem definidos.

Este trabalho é a proposta de um algoritmo para classificação de cerâmicas com aplicação no controle de qualidade. O algoritmo usa técnicas de lógica difusa em imagens de cerâmicas lisas. Os defeitos são caracterizados como mancha e descasamento de tonalidade. Com o uso dos conceitos de função de pertinência, variáveis lingüísticas e grupo de treinamento, as cerâmicas são classificadas em três classes de saída. Cada classe tem o seu grau de qualidade associado.

Palavras-chave:

- Controle de qualidade;
- Lógica difusa;
- Funções de pertinência;
- Variáveis lingüísticas.

ABSTRACT

Fuzzy logic has had a great application due to its uncertainty treatment, producing new methods of acquisition, representation and use of knowledge. In the industrial inspection field, the interest in this kind of system is growing because in most cases the characteristic frontier of each inspected object is not clearly defined.

This work describes an algorithm for ceramic classification with application in quality control. The algorithm uses fuzzy logic techniques on the images of ceramic tiles. The defects analyzed are characterized as spots and tone mismatch. Using the concepts of membership functions, linguistic variables and training group, the ceramic tiles are classified into three output classes. Each class corresponds to a different quality degree.

Keywords:

- *Quality control;*
- *Fuzzy logic;*
- *Membership functions;*
- *Linguistic variables.*

CAPÍTULO 1

INTRODUÇÃO

A implementação de sistemas que emulem a visão humana ou mesmo a superem em determinadas aplicações é uma realidade. A visão artificial tem sido aplicada na interpretação de fotos aéreas, reconhecimento automático de alvos ou ainda no melhoramento de imagens que possibilitem diagnósticos médicos [1]. Em muitas dessas aplicações as técnicas de reconhecimento de padrões estão presentes. Em síntese, essas técnicas procuram encontrar uma regularidade em uma estrutura de dados e com isso possibilitar a análise de características, classificação e agrupamento, viabilizando a tomada de decisões e ações de controle [2].

A maior parte dos sistemas visuais automáticos têm aplicação na indústria. Como exemplos, tem-se a técnica de orientação e posicionamento de objetos, muito usada na indústria automobilística e a *inspeção automática* de placas de circuitos impressos, entre outras [3].

A inspeção é uma etapa importante em muitos meios industriais. A inspeção visual automática pode ser definida como um conjunto de técnicas que vão desde a captação das informações pelos sensores até a aplicação de algoritmos e ação de atuadores, que tornam possível o *controle de qualidade* dos produtos de uma indústria. Nos processos de inspeção visual automáticos em tempo real destaca-se a complexidade computacional dos algoritmos, que deve ser pequena e os processadores, que devem ter arquiteturas dedicadas [4]. O monitoramento automático tem diversas aplicações, com destaque para a substituição do homem em locais

perigosos ou de difícil acesso [5] e em sistemas mais genéricos, visando compatibilizar as fases de produção e inspeção, frente às atuais velocidades de fabricação.

Uma aplicação comum dos sistemas de inspeção visual automática é a *medição de dimensões críticas* para se eliminar peças fora das especificações [6]. Às vezes esta aplicação encontra-se incorporada em um subsistema do processo de montagem, seja ele automático ou não. Uma outra aplicação importante é a *inspeção de itens* na procura de amostras defeituosas e/ou para classificação em diferentes grupos [7]. Esta última aplicação é a mais difícil de ser implementada automaticamente, pois deve-se fazer o julgamento da aparência visual do objeto e, devido a isso, a indústria vem usando inspetores humanos.

A inspeção de itens baseia-se na observação de um mesmo tipo de peça e comparação com um padrão. Considerando que na maioria das indústrias os produtos apresentam um alto índice de uniformidade, exige-se uma grande concentração por parte do operador. O processo é repetitivo e monótono e nem sempre as dimensões dos defeitos significativos encontram-se dentro dos limites de percepção de um inspetor humano. Ainda há o problema dos ambientes onde se realiza o trabalho não apresentarem, na maioria das vezes, condições satisfatórias de luminosidade, temperatura e nível de ruído, dentre outros. E finalmente, de acordo com estudos e avaliações realizados [8,9], sabe-se que o desempenho do sistema visual humano declina com as tarefas monótonas e rotineiras, permitindo, em um processo de avaliações contínuas, que peças defeituosas não sejam percebidas. É aqui que um sistema visual automático representa uma alternativa vantajosa frente ao inspetor humano. Características como a compatibilidade entre as velocidades de produção e inspeção, exatidão, consistência e relação

custo-benefício, representam vantagens com relação aos aspectos qualitativos e quantitativos de produção e economia a médio e longo prazo frente ao inspetor humano.

Em [10] é descrito um algoritmo de um sistema visual automático cuja função principal é classificar itens. Para a implementação de sistemas como esse, deve-se primeiro fazer a seleção de características mais apropriadas para se reduzir a quantidade de informação que será submetida ao processador. É sabido que imagens geram um volume grande de informações devido às dimensões das matrizes usadas para representá-las. Tem-se, assim, a necessidade de utilizar funções de mapeamento entre espaços de características, de forma a reduzir a quantidade de dados para o processamento e destacar as características desejáveis à avaliação. Os espaços de características representam as diferentes classes que serão utilizadas no processo de classificação de uma amostra [10]. Essas classes são obtidas através de um grupo de peças com identificação conhecida chamado de *conjunto de treinamento* ou *conjunto de projeto*. Ter-se-ia o caso ideal se essas classes, obtidas a partir do conjunto de treinamento, tivessem interseção nula, mas na maioria dos casos ocorre a sobreposição, levando a alguma imprecisão na classificação.

Uma característica bastante utilizada para classificação de itens é a textura [10,11]. A textura apresenta propriedades como rugosidade, contraste e direcionalidade que podem ser representadas usando métodos estatísticos de primeira e segunda ordens [12]. É importante ressaltar o uso das matrizes de co-ocorrências que levam em consideração a dependência espacial dos níveis de cinza de uma imagem. Em [10], através do uso da estatística de diferença, um subconjunto das matrizes de co-ocorrência, pôde-se destacar duas classes bem definidas entre peças a serem classificadas: *aceitada* e *rejeitada*. No entanto esse método não apresenta interseção baixa entre três ou mais classes obtidas do conjunto de treinamento. Uma solução para

esse problema é o uso de outras técnicas, dentre as quais destacam-se as baseadas em *lógica difusa*.

A lógica difusa nasceu da necessidade de se tomar decisões baseadas em informações vagas, ambíguas e qualitativamente incompletas ou imprecisas [13]. Trata-se de um superconjunto da lógica convencional que foi estendido para manipular o conceito de verdade parcial [14,15].

Na *lógica Booleana* ou *convencional* tem-se a pertinência de um elemento e um conjunto relacionados através da *função característica*. Esta função pode assumir o valor 1 ou 0, ou seja, pertence ou não pertence em resposta à pergunta: “O elemento x pertence ao conjunto X ?” Já os conjuntos difusos têm elemento e conjunto associados à uma *função de pertinência* que pode assumir qualquer valor entre 0 e 1, com relação a mesma pergunta anterior. A Fig. 1.1 ilustra esta relação elemento-conjunto para as duas lógicas. A função característica é chamada na figura de $f(x)$ e a função de pertinência de $\mu(x)$ [16].

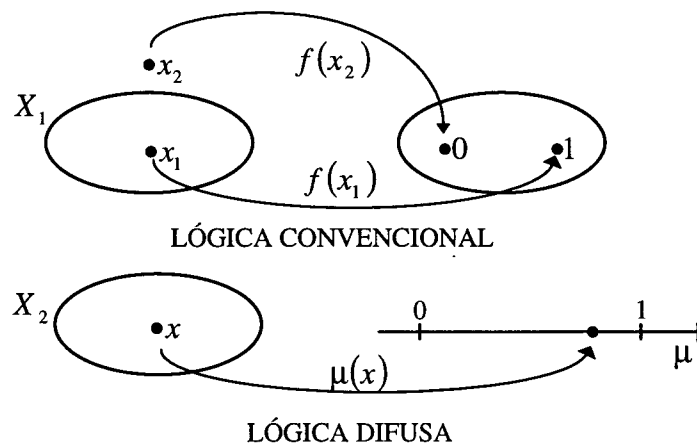


Fig. 1.1 - Lógica convencional e lógica difusa.

A idéia da função de pertinência é estabelecer uma premissa que varia em graus de certeza. Esta característica se aproxima mais do raciocínio humano por este ser heurístico e impreciso.

Outra ferramenta importante da lógica difusa é a *variável lingüística*. As variáveis lingüísticas são grupos rotulados qualitativamente [17]. A associação de termos lingüísticos (como, por exemplo, baixo, quente, seco, etc.) às funções de pertinência tornam o processo de tomada de decisão simples e eficaz.

A lógica difusa é uma ferramenta que vem sendo usada em sistemas de controle de temperatura, controle de elevadores, controle de autofocus de câmera de vídeo [18], diagnósticos médicos [19], controle de veículos [20], reconhecimento de caracteres manuscritos [21] segmentação de imagens aéreas [22], dentre outros.

Na indústria, a lógica difusa tem sido aplicada sistematicamente, garantindo precisão e rapidez aos processos de análise [23] ou inspeção [24]. As aplicações se estendem também a *cluster analysis* [25] e projeto de classificadores [26]. Fica evidente a versatilidade dessa técnica pela diversidade dos exemplos citados.

O presente trabalho aborda o emprego da inspeção visual automática utilizando lógica difusa. A metodologia de análise foi desenvolvida para ser utilizada pela indústria cerâmica. Neste tipo de aplicação é requerido que 100% dos produtos sejam visualmente inspecionados. O controle visual do produto é realizado com o objetivo de se fazer o controle de qualidade, ou seja, detectar defeitos e separar as peças em classes de acordo com estes defeitos, a fim de manter a qualidade exigida por um mercado cada vez mais competitivo.

Os tipos de defeitos que devem ser detectados estão relacionados com a aparência da peça. Estes defeitos são conhecidos na literatura como *defeitos cosméticos*. Os tipos mais comuns de defeitos podem acontecer em duas regiões da peça cerâmica: no perímetro e na superfície. Os defeitos no perímetro ocorrem sob a forma de cantos quebrados e/ou bordas lascadas. Os defeitos na superfície podem pertencer à duas classes: defeitos no desenho decorativo e saliências na superfície da peça.

Neste trabalho propõe-se um algoritmo de inspeção visual automático baseado em lógica difusa com o objetivo da detecção dos defeitos cosméticos de superfície. O algoritmo desenvolvido para o problema da inspeção automática de *cerâmicas lisas* faz a separação dos objetos em classes, cada uma com seu grau de qualidade.

No Capítulo 2 são apresentados os tipos de objetos que serão tratados e os defeitos que eles apresentam. No Capítulo 3 é apresentado o conceito de lógica difusa e os processos a ela inerentes usados para classificar cerâmicas levando-se em consideração os defeitos de mancha e variação na tonalidade da peça. No Capítulo 4 aborda-se a metodologia usada para aplicar lógica difusa na classificação de cerâmica. No Capítulo 5 têm-se os resultados experimentais, que indicam a habilidade do algoritmo para a detecção de defeitos. E finalmente, no Capítulo 6 são apresentadas as conclusões e sugestões deste trabalho.

CAPÍTULO 2

APRESENTAÇÃO DOS OBJETOS SOB ANÁLISE

2.1 Introdução

Até o presente não foi desenvolvido um sistema de visão artificial de propósito geral que se iguale em desempenho ao sistema visual dos seres humanos. Portanto, um sistema destinado a realizar uma tarefa de inspeção visual automática deve operar sobre objetos específicos ou classes de objetos. Esta operação deve ocorrer em condições cuidadosamente controladas para maximizar seu desempenho. Assim, quanto maior for o conhecimento dos objetos a serem analisados e dos tipos de defeitos que eles podem conter, melhor e mais precisamente será definida uma abordagem para a solução do problema.

Em geral, defeito é a falta de conformidade de alguma característica de um produto quando comparado com seu respectivo padrão. O conceito de defeito encontra-se intimamente relacionado com a definição de peça padrão. Uma definição clara e objetiva de padrões possibilitará a criação de bases robustas de análise que permitam a avaliação da qualidade da peça. Neste capítulo são apresentados os objetos sob análise juntamente com os defeitos que eles apresentam.

Foram utilizados dois grupos de cerâmicas lisas para testes do algoritmo proposto. O primeiro conjunto tem uma tonalidade clara e será denotado por Grupo I. Já o segundo conjunto tem uma tonalidade escura e será denotado por Grupo II.

2.2 Processos de Decoração

Existem, basicamente, três tipos de processos que permitem decorar a superfície de uma cerâmica: pintura, litografia e texturização.

A cerâmica mostrada na Fig. 2.1 é decorada pelo processo de pintura. Nesse caso, as peças são pintadas por um jato de tinta de uma única cor. As cerâmicas assim manufaturadas pertencem ao conjunto das *cerâmicas lisas*, classe essa que será alvo do algoritmo de classificação deste trabalho.




Fig. 2.1 - Cerâmica lisa sem defeitos (Grupo I).

As cerâmicas decoradas por litografia têm como característica um alto índice de uniformidade no desenho decorativo. Esse desenho é montado em uma ou mais etapas, dependendo do número de cores que ele possua. Uma das formas de montagem de cada etapa (ou cor) é usar placas litográficas diferentes que se encaixam sobre a cerâmica.

E finalmente, a decoração usando o processo de texturização monta na cerâmica uma trama fina, grossa ou periódica, variando o tom e o tipo de textura [10].

2.3 Tipos de Defeitos nas Cerâmicas Lisas

Não existe uma cerâmica que possa ser considerada perfeita do ponto de vista de não possuir defeitos. Com isso, trabalha-se com cerâmicas aceitáveis. Uma cerâmica é considerada de boa qualidade quando o número de defeitos cosméticos é aceitável pelo controle de qualidade [27]. Pode-se destacar dois tipos de defeitos principais que podem acontecer na superfície de uma cerâmica lisa: *manchas* e *variação na tonalidade*.

As manchas são pequenas áreas na peça com cor diferente do padrão. Dependendo da cor da cerâmica podem existir manchas claras e escuras. Na Fig. 2.2 pode-se observar, destacada na imagem, uma mancha escura, mancha essa que pode tornar essa peça não aceitável.




Fig. 2.2 - Cerâmica lisa com mancha (Grupo I).

Pode ocorrer também a presença de pequenas manchas espalhadas pela superfície que muitas vezes não chegam a inutilizar a peça. Essa situação pode ser vista na Fig. 2.3, onde têm-se manchas pequenas destacadas.




Fig. 2.3 - Cerâmica lisa com manchas espalhadas (Grupo I).

A variação na tonalidade é a mudança da cor da peça numa determinada região ou por toda a superfície. Também aqui, dependendo da cor da cerâmica, tem-se a tonalidade mais escura ou mais clara que o padrão. As Figs. 2.4 e 2.5 mostram o defeito de tonalidade mais escura e uma cerâmica padrão, respectivamente.

Duas cerâmicas pertencentes ao Grupo II (tonalidade mais escura) são mostradas em seguida. A Fig. 2.6 tem-se a peça sem defeitos. Já a Fig. 2.7 mostra uma cerâmica escura com manchas espalhadas pela peça.




Fig. 2.4 - Cerâmica lisa com tonalidade mais escura (Grupo I).




Fig. 2.5 - Cerâmica lisa com tonalidade normal (Grupo I).




Fig. 2.6 - Cerâmica de tonalidade escura sem defeitos (Grupo II).



Fig. 2.7 - Cerâmica de tonalidade escura com manchas (Grupo II).

2.4 Conclusões

A noção de estrutura de defeito e o conhecimento preciso dos objetos são essenciais para a precisa especificação da abordagem do problema em questão. Deve-se ter em mente, também, que tal abordagem deve ser compatível com a filosofia de projeto de sistema que possa ser utilizado pela indústria.

Os conceitos de mancha e variação na tonalidade, em uma cerâmica, não são capazes de precisar, qualitativamente ou quantitativamente, o quanto uma peça, apresentando esses defeitos, pode ser considerada de boa qualidade ou pertencer a classes de qualidade inferior. Com isso, fica clara a importância de se fazer a classificação levando-se em conta a imprecisão que as definições de defeito trazem em si.

CAPÍTULO 3

LÓGICA DIFUSA

3.1 Introdução

A teoria dos conjuntos difusos foi formalizada em 1965 por Lotfi Zadeh [16] mas teve uma atenção maior de pesquisadores nos últimos anos, haja vista a quantidade de trabalhos, artigos e livros publicados. O interesse atual deve-se à crescente necessidade de sistemas que tenham metodologia baseada na imprecisão e ambigüidade. Sistemas assim tornam possível uma interação maior entre homem e máquina já que as ferramentas que o sistema usa aproximam-se da linguagem do dia a dia das pessoas.

Neste capítulo são apresentados os conceitos básicos sobre lógica difusa que são relevantes para o entendimento deste trabalho. Na sequência, tem-se um enfoque dessa técnica aplicada à classificação de cerâmicas lisas.

3.2 Conceito de Lógica Difusa

A *teoria dos conjuntos difusos* está baseada na idéia de representar elementos e conjuntos tendo como fundamento uma relação de pertinência vaga, incerta, ambígua ou indefinida [16].

Primeiro será analisado a relação entre elemento e conjunto definida para a *lógica booleana*. Se X é uma coleção de objetos representados genericamente por x , então o conjunto convencional A em X é um conjunto de pares ordenados dado por:

$$A = \{(x, f_A(x))\} \quad (3.1a)$$

onde,

$$f_A : X \rightarrow \{0,1\} \quad (3.1b)$$

$$f_A(x) = \begin{cases} 1, & \text{se } x \in X \\ 0, & \text{se } x \notin X \end{cases} \quad (3.1c)$$

A função f_A é chamada *função característica* do conjunto A . Esta função mapeia todos os elementos de X dentro de dois pontos $\{0,1\}$, que correspondem a dois valores lógicos: desligado ou ligado, não ou sim, 0 ou 1. Sabe-se que essa definição é muito útil para tratar situações bem definidas. Esses conceitos podem ainda ser expandidos com vistas a trabalhar com incertezas.

Se X é uma coleção de objetos representados genericamente por x , então o conjunto difuso \underline{A} em X é um conjunto de pares ordenados dados por:

$$\underline{A} = \{(x, \mu_{\underline{A}}(x))\} \quad (3.2a)$$

onde,

$$\mu_{\underline{A}} : X \rightarrow [0,1] \quad (3.2b)$$

$$\mu_{\underline{A}}(x) = \begin{cases} \mu_{\underline{A}} = 1, & \text{se } x \in \text{totalmente a } X, \text{ ou} \\ \mu_{\underline{A}} = 0, & \text{se } x \notin X, \text{ ou} \\ 0 < \mu_{\underline{A}} < 1, & \text{se } x \in \text{parcialmente a } X \end{cases} \quad (3.2c)$$

A função μ_A é chamada *função de pertinência* do conjunto difuso A [28]. Em A a resposta exata é um caso limite da resposta aproximada. Pode-se concluir que a definição de conjunto difuso é uma generalização da definição de conjuntos convencionais.

3.3 Função de Pertinência

A função de pertinência tem sido uma ferramenta poderosa para representar a ambigüidade de adjetivos da linguagem natural. Por exemplo, quando se fala em “temperatura alta” fica difícil associar um número e determinada unidade. O mesmo acontece com a expressão “pessoa velha”. É indefinido os limites da característica idade. Assim, usa-se uma curva distribuída com *graus de pertinência*, que representa melhor a característica ambígua em questão para tratá-la matematicamente. A curva que *quantifica o significado* de um termo lingüístico é denominada *função de pertinência*.




Fig. 3.1 - Exemplos de função de pertinência

Pode-se considerar que o intervalo conveniente para representar “temperatura alta”, em graus Celsius, seja de 25 a 50 e a melhor curva seja uma reta. Escolhido o domínio e o tipo da curva têm-se todos os valores, neste intervalo, com seu grau de pertinência associado.

Esse grau de pertinência traz em si o quanto determinada temperatura faz parte do conjunto “temperatura alta”. Da mesma forma pode-se representar a ambigüidade da expressão “pessoa velha”. Na Fig. 3.1 têm-se duas possíveis funções de pertinência para representar “temperatura alta” e “pessoa velha”.

3.3.1 Características de uma Função de Pertinência

Já ficou evidenciado a importância das funções de pertinência com respeito à representação das informações de um conjunto difuso. Agora será abordada a terminologia usada para descrever uma função de pertinência.




Fig. 3.2 - Centro, suporte e fronteiras de um conjunto difuso [29].

Suporte de uma função de pertinência para um conjunto difuso A qualquer é definido como a região onde a pertinência é diferente de zero.

O *centro* de uma função de pertinência é a região do suporte cujos elementos têm pertinência máxima.

A *fronteira* (ou *limite*) é a região do suporte cujos elementos têm pertinência menor que a máxima.

Um *conjunto difuso normalizado* é aquele que tem pelo menos um elemento no universo com valor de pertinência igual a um . A Fig. 3.3 mostra um conjunto difuso normalizado e outro não-normalizado.




Fig. 3.3 - Conjunto difuso normalizado e não-normalizado.

Se para todos os elementos de um conjunto difuso A onde $x < y < z$, então A é dito *conjunto difuso convexo* se, e somente se:

$$\mu_A(y) \geq \min^1[\mu_A(x), \mu_A(z)] \quad (3.3)$$

A Fig. 3.4 mostra um conjunto difuso convexo e outro não-convexo [30].




Fig. 3.4 - Conjunto difuso convexo e não-convexo.

1. "min" subentende-se tomar o valor mínimo.

Uma característica especial com respeito a dois conjuntos difusos convexos é que a interseção entre eles é também convexa.




Fig. 3.5 - Interseção de dois conjuntos difusos convexos

3.3.2 Tipos de Função de Pertinência

A função de pertinência é, essencialmente, uma curva distribuída com graus de pertinência que melhor representem as propriedades semânticas de uma palavra ou expressão lingüística. Essas funções podem assumir qualquer formato, no entanto algumas curvas padrão são mais utilizadas.

Dentre as curvas mais usadas estão as *triangulares* e *trapezoidais* que são também as mais simples. A Fig. 3.6 mostra estas curvas.




Fig. 3.6 - Curvas de pertinência triangular e trapezoidal.

Já dentro da classe de curvas não lineares têm-se as *curvas “S”* e também as *curvas sino* [28]. As curvas sino mais utilizadas são: π , Beta e Gauss. A diferença entre elas está na inclinação da curva e nos valores dos pontos extremos. Na Fig. 3.7 têm-se representadas as curvas “S” e sino.




Fig. 3.7 - Curvas em “S” e sino

3.4 Variável Lingüística e Valor Lingüístico

Um conjunto difuso trabalha com a incerteza modelada através de funções de pertinência ao invés das função de transferência dos sistemas convencionais. Além disso, ainda faz-se a associação do conceito de *variável lingüística* ao conjunto difuso. À função de pertinência associa-se o conceito de *valor lingüístico* [31,32]. Variável e valor lingüísticos são, simplesmente, expressões ou palavras da linguagem natural.

Foi usada, anteriormente, a característica temperatura para explicar a ambigüidade presente em uma função de pertinência. Pode-se estender um pouco mais essa característica para exemplificar os conceitos anteriormente mencionados.

Na Fig. 3.8 tem-se a variável lingüística TEMPERATURA podendo assumir três valores lingüísticos: **frio**, **normal** e **quente**. São os valores lingüísticos que armazenam o




Fig. 3.8 - Variável lingüística TEMPERATURA e seus valores lingüísticos.

grau de pertinência de um determinado elemento. Ainda nessa figura, tem-se a temperatura de 28°C que recebe dois valores lingüísticos: **normal**, com grau de pertinência 0,8 e **quente**, com grau de pertinência 0,2. O processo difuso com certeza usará o fato de a temperatura de 28°C ser normal e quente, mas o valor lingüístico **normal** tem uma ponderação maior.

3.5 Operações com Conjuntos Difusos [28] [29] e [30]

Os conjuntos difusos estão definidos pelas suas funções de pertinência, então as operações com conjuntos difusos envolvem tão somente estas funções.

3.5.1 União

A união dos conjuntos difusos \underline{A} e \underline{B} , representada por $\underline{A} \cup \underline{B}$ é definida pela função de pertinência do seguinte conjunto difuso:

$$\mu_{\underline{A} \cup \underline{B}}(x) = \mu_{\underline{A}}(x) \vee \mu_{\underline{B}}(x) \quad (3.4)$$

$$\mu_{\underline{A} \cup \underline{B}}(x) = \max^2 \{ \mu_{\underline{A}}(x), \mu_{\underline{B}}(x) \}, x \in X$$

2. “max” subentende-se tomar o valor máximo.

3.5.2 Interseção

A interseção dos conjuntos difusos \underline{A} e \underline{B} , representada por $\underline{A} \cap \underline{B}$ é definida pela função de pertinência do seguinte conjunto difuso:

$$\mu_{\underline{A} \cap \underline{B}}(x) = \mu_{\underline{A}}(x) \wedge \mu_{\underline{B}}(x) \quad (3.5)$$

$$\mu_{\underline{A} \cup \underline{B}}(x) = \min\{\mu_{\underline{A}}(x), \mu_{\underline{B}}(x)\}, x \in X$$

3.5.3 Complemento

O complemento do conjunto difuso \underline{A} , representado por $\bar{\underline{A}}$ é definido pela função de pertinência do seguinte conjunto difuso:

$$\mu_{\bar{\underline{A}}}(x) = 1 - \mu_{\underline{A}}(x), x \in X \quad (3.6)$$

Pode-se observar a representação gráfica dos operadores difusos na Fig. 3.9.




Fig. 3.9 - Operações básicas com conjuntos difusos.

3.6 Propriedades dos Conjuntos Difusos [28] e [30]

3.6.1 Comutatividade

$$\underline{A} \cup \underline{B} = \underline{B} \cup \underline{A} \quad (3.7a)$$

$$\underline{A} \cap \underline{B} = \underline{B} \cap \underline{A} \quad (3.7b)$$

3.6.2 Associatividade

$$\underline{A} \cup (\underline{B} \cup \underline{C}) = (\underline{A} \cup \underline{B}) \cup \underline{C} \quad (3.8a)$$

$$\underline{A} \cap (\underline{B} \cap \underline{C}) = (\underline{A} \cap \underline{B}) \cap \underline{C} \quad (3.8b)$$

3.6.3 Distributividade

$$\underline{A} \cup (\underline{B} \cap \underline{C}) = (\underline{A} \cup \underline{B}) \cap (\underline{A} \cup \underline{C}) \quad (3.9a)$$

$$\underline{A} \cap (\underline{B} \cup \underline{C}) = (\underline{A} \cap \underline{B}) \cup (\underline{A} \cap \underline{C}) \quad (3.9b)$$

3.6.4 Idempotência

$$\underline{A} \cup \underline{A} = \underline{A} \quad (3.10a)$$

$$\underline{A} \cap \underline{A} = \underline{A} \quad (3.10b)$$

3.6.5 Identidade

$$\underline{A} \cup \emptyset = \underline{A} \quad e \quad \underline{A} \cup X = X \quad (3.11a)$$

$$\underline{A} \cap X = \underline{A} \quad e \quad \underline{A} \cap \emptyset = \emptyset \quad (3.11b)$$

3.6.6 Transitividade

$$\text{Se } \underline{A} \subseteq \underline{B} \subseteq \underline{C} \text{ então, } \underline{A} \subseteq \underline{C} \quad (3.12)$$

3.6.7 Involução

$$\overline{\overline{\underline{A}}} = \underline{A} \quad (3.13)$$

3.6.8 Lei de Morgan

$$\overline{(A \cap B)} = \bar{A} \cup \bar{B} \quad (3.14a)$$

$$\overline{(A \cup B)} = \bar{A} \cap \bar{B} \quad (3.14b)$$

3.6.9 Lei do Meio Excluído

A lei do meio excluído não se aplica aos conjunto difusos da forma que é aplicada aos conjuntos convencionais, pois aqueles podem sobrepor-se.

$$\underline{A} \cup \underline{A} \neq X \quad (3.15a)$$

$$\underline{A} \cap \underline{A} \neq \emptyset \quad (3.15b)$$

3.7 Operações Algébricas com Conjuntos Difusos[32]

3.7.1 Produto Cartesiano

Se $\underline{A}_1, \underline{A}_2, \dots, \underline{A}_n$ são conjuntos difusos em X_1, X_2, \dots, X_n , o produto cartesiano é então um conjunto no espaço dos produtos $X_1 \times X_2 \times \dots \times X_n$ com a seguinte função de pertinência:

$$\mu_{(\underline{A}_1 \times \underline{A}_2 \times \dots \times \underline{A}_n)}(x) = \min_i \{\mu_{\underline{A}_i}(x_i) \mid x = (x_1, x_2, \dots, x_n), x_i \in X_i\} \quad (3.16)$$

3.7.2 Enésima potência

A enésima potência de \underline{A} é um conjunto difuso com a seguinte função de pertinência:

$$\mu_{\underline{R}^n}(x) = [\mu_{\underline{A}}(x)]^n, \quad x \in X \quad (3.17)$$

3.7.3 Soma Algébrica

A soma algébrica $\underline{C} = \underline{A} + \underline{B}$ é definida como:

$$\underline{C} = \{(x, \mu_{\underline{A}+\underline{B}}(x)) \mid x \in X\} \quad (3.18a)$$

onde,

$$\mu_{\underline{A}+\underline{B}}(x) = \mu_{\underline{A}}(x) + \mu_{\underline{B}}(x) - \mu_{\underline{A}}(x)\mu_{\underline{B}}(x) \quad (3.18b)$$

3.7.4 Produto Algébrico

O produto algébrico $\underline{C} = \underline{A} \bullet \underline{B}$ é definido como :

$$\underline{C} = \{(x, \mu_{\underline{A}}(x)\mu_{\underline{B}}(x)) \mid x \in X\} \quad (3.19)$$

3.7.5 Soma Limitada

A soma limitada $\underline{C} = \underline{A} \oplus \underline{B}$ é definida como :

$$\underline{C} = \{(x, \mu_{\underline{A} \oplus \underline{B}}(x)) \mid x \in X\} \quad (3.20a)$$

onde,

$$\mu_{\underline{A} \oplus \underline{B}}(x) = \min\{1, \mu_{\underline{A}}(x) + \mu_{\underline{B}}(x)\} \quad (3.20b)$$

3.7.6 Diferença Limitada

A diferença limitada $\underline{C} = \underline{A} \ominus \underline{B}$ é definida como:

$$\underline{C} = \{(x, \mu_{\underline{A} \ominus \underline{B}}(x)) / x \in X\} \quad (3.21a)$$

onde ,

$$\mu_{\underline{A} \ominus \underline{B}}(x) = \max\{0, \mu_{\underline{A}}(x) + \mu_{\underline{B}}(x) - 1\} \quad (3.21b)$$

Será feito um exemplo de aplicação desses operadores. Dados os seguintes conjuntos:

$$\underline{A} = \{(2; 0,5), (4; 0,9), (6; 0,7)\}$$

$$\underline{B} = \{(2; 1), (6; 0,6)\} = \{(2; 1), (4; 0), (6; 0,6)\}$$

Aplicando cada um dos operadores, obtêm-se:

$$\underline{A} \times \underline{B} = \{[(2; 2); 0,5], [(4; 2); 0,9], [(6; 2); 0,7], [(2; 6); 0,5], [(4; 6); 0,6], [(6; 6); 0,6]\}$$

$$\underline{A}^2 = \{(2; 0,25), (4; 0,81), (6; 0,49)\}$$

$$\underline{A} \bullet \underline{B} = \{(2; 0,5), (4; 0), (6; 0,42)\}$$

$$\underline{A} + \underline{B} = \{(2; 1), (4; 0,9), (6; 1)\}$$

$$\underline{A} \oplus \underline{B} = \{(2; 1), (4; 0,9), (6; 1)\}$$

$$\underline{A} \ominus \underline{B} = \{(2; 0,5), (4; 0), (6; 0,3)\}$$

3.8 Sistema Difuso [33]

Um sistema convencional, em geral, analisa dados de entrada provenientes de sensores, compara-os à referência(s), faz um processamento e fornece um sinal para os atuadores que modificam a saída do processo.

Um sistema difuso (Fig. 3.10) é uma estrutura baseada na lógica difusa que trata as entradas de forma nebulosa e responde com um valor *crisp* na saída.

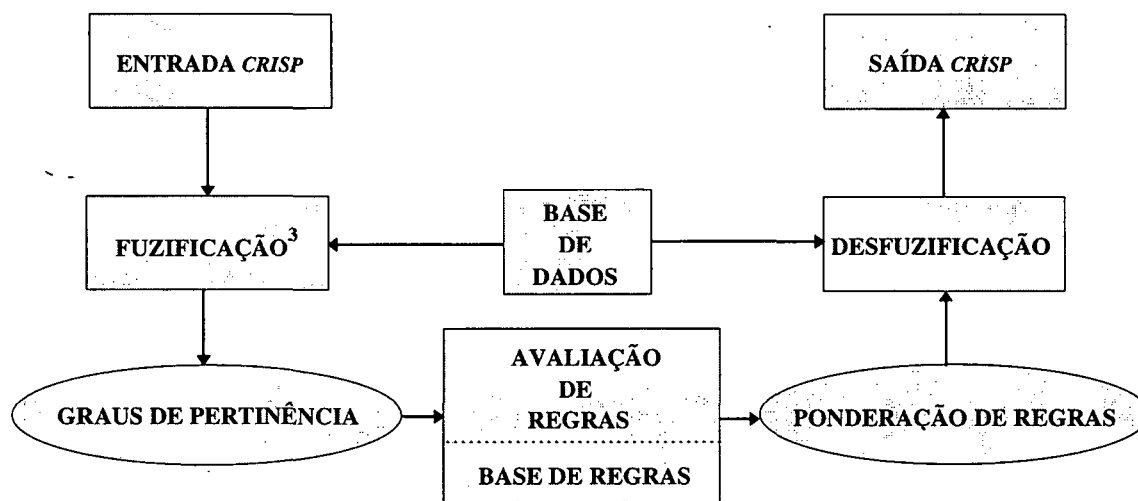


Fig. 3.10 - Fluxo de dados de um sistema difuso.

3.8.1 Base de Dados

Na base de dados estão definidas as funções de pertinência para as variáveis de entrada e saída. As funções são usadas na *fuzificação* e *desfuzificação*. Além disso, os valores lingüísticos destas funções de pertinência são utilizados pela *base de regras* difusas. A Fig. 3.11 ilustra funções de pertinência que serão usadas em um exemplo de sistema difuso.

3 Fuzificação e palavras derivadas são neologismos criados com o fim de descrever etapas do processo difuso.

O exemplo será de um regador automático de jardim. Têm-se dois sensores responsáveis pelas variáveis de entrada: um para medir temperatura e outro para medir umidade do solo. O objetivo do sistema é molhar o jardim num tempo coerente com respeito às variáveis de entrada.




Fig. 3.11 - Funções de pertinência para o exemplo.

3.8.2 Fuzificação

A fuzificação é a etapa inicial na qual um valor (*crisp*) de entrada é transformado em um ou mais graus de pertinência. Cada grau de pertinência, por sua vez, é associado à um valor lingüístico. Ainda na Fig. 3.11, os valores de entrada para temperatura (31°C) e umidade do solo (70 ml/dm³) são fuzificados. A tabela abaixo resume as informações obtidas da fuzificação do sistema.

Tabela 3.1 - Fuzificação das variáveis de entrada do exemplo.

VARIÁVEIS LINGÜÍSTICAS			
TEMPERATURA = 31°C		UMIDADE DO SOLO = 70 ml/dm ³	
VALOR LINGÜÍSTICO	GRAU DE PERTINÊNCIA	VALOR LINGÜÍSTICO	GRAU DE PERTINÊNCIA
Frio	0,0	Seco	0,8
Normal	0,6	Úmido	0,2
Quente	0,4	Molhado	0,0

3.8.3 Avaliação de Regras

Para fazer a inferência do sistema difuso o projetista desenvolve uma *base de regras*. As regras difusas são, usualmente, declarações “**IF - THEN**” que descrevem as ações a serem tomadas em resposta à(s) entrada(s) difusa(s). O lado “**IF**” de uma regra contém uma ou mais condições denominadas *antecedentes*. No lado “**THEN**” tem-se uma ou mais ações chamadas *conseqüentes*. Cada valor lingüístico na função de pertinência de saída deve apresentar o grau de pertinência mais representativo possível dos efeitos das entradas. As formas mais usuais de se combinar os graus de pertinência de antecedentes e conseqüentes são:

Método de inferência Max-Min: onde os consequentes são compostos pelo valor *mínimo* entre os antecedentes (operador interseção: AND) e as entradas da fase de desfuzificação são obtidas tomado o valor *máximo* dos consequentes (operador união: OR) [30],[34].

Método de inferência Max-Produto: onde os consequentes são compostos pelo *produto* entre os valores dos antecedentes e as entradas da fase de desfuzificação são obtidas tomado o valor *máximo* dos consequentes [30].

Com os métodos apresentados chega-se, praticamente, ao mesmo resultado final, sendo assim será usado no exemplo o *método de inferência Max-Min*. Será apresentado, a seguir, uma possível base de regras para o regador automático.

Base de Regras

Regra 1:

“IF TEMPERATURA é quente (0,4.) AND MISTURA DO SOLO é seco (0,8)

THEN TEMPO DE OPERAÇÃO é longo (0,4)”

Regra 2:

“IF TEMPERATURA é normal (0,6.) AND MISTURA DO SOLO é úmido (0,2)

THEN TEMPO DE OPERAÇÃO é médio (0,2)”

Regra 3:

“IF TEMPERATURA é frio (0,0.) AND MISTURA DO SOLO é molhado (0,0)

THEN TEMPO DE OPERAÇÃO é curto (0,0)”

Regra 4:

“IF TEMPERATURA é normal (0,6.) AND MISTURA DO SOLO é seco (0,8)

THEN TEMPO DE OPERAÇÃO é longo (0,6)”

A ponderação dos valores lingüísticos de saída, também chamado de *composição*, é feita aplicando, como visto anteriormente, o operador união aos graus de pertinência. A Tabela 3.2 mostra os valores resultantes da fase de avaliação de regras e entrada da fase desfuzificação.

Tabela 3.2 - Valores de pertinência obtidos da avaliação das regras.

VALOR LINGÜÍSTICO	GRAU DE PERTINÊNCIA
Curto	0,0
Médio	0,2
Longo	0,6

3.8.4 Desfuzificação

O objetivo da desfuzificação é transformar os valores difusos de saída em um valor *crisp*. Para isso serão usadas as funções de pertinência de saída com seus valores lingüísticos ponderados na etapa anterior. Essa nova etapa também será explicada através do exemplo. Primeiro é tomado o gráfico de saída (Fig. 3.11c) e faz-se um truncamento das curvas usando os valores de pertinência de saída (Tabela 3.2). A curva obtida desse truncamento é denotada por $f(x)$. A Fig. 3.12 mostra as funções de pertinência de saída truncadas.




Fig. 3.12 - Função de pertinência de saída com truncamento.

O próximo passo é aplicar um dos métodos de desfuzificação. Serão apresentados os mais usuais.

3.8.4.1 Método do Centróide

O *método do centóide* ou *método do centro de gravidade* calcula a abscissa do centro de gravidade da área formada sob a curva $f(x)$. Para isso é feita a divisão entre o momento da curva $f(x)$ e sua área. Com isso tem-se a seguinte equação:

$$S = \frac{\int_{x_0}^{x_1} x f(x) dx}{\int_{x_0}^{x_1} f(x) dx} \quad (3.22)$$

Aplicando-se a equação (3.22) à função representada pela Fig. 3.11c, tem-se:

$$S = 284/10,4 = 27,31$$

O tempo de operação do regador para as entradas apresentadas será de 27,31 min. Percebe-se, pela Fig. 3.12, que existe um tempo mínimo e um tempo máximo de operação do regador. Esses tempos podem ser modificados alterando-se as curvas de pertinência de saída ou deslocando-as no eixo das abscissas.

Na prática não se usa a função de desfuzificação contínua, mas sim amostrada.

Amostrando-se $f(x)$, tem-se a seguinte expressão:

$$S = \frac{\sum_{x=a}^b x f(x)}{\sum_{x=a}^b f(x)} \quad (3.23)$$

No exemplo, usando amostras espaçadas de 5 unidades, tem-se:

$$S = \frac{0,0.10 + 0,2.15 + 0,2.20 + 0,5.25 + 0,6.30 + 0,5.35 + 0,0.40}{0,0 + 0,2 + 0,2 + 0,5 + 0,6 + 0,5 + 0,0}$$

$$S = 27,5 \text{ min.}$$

3.8.4.2 Método das Barras Verticais (Singletons)

Simplificando o método do centóide chega-se ao método das barras verticais.

Nesse método, cada função de pertinência é representada por uma única amostra truncada pelo valor de pertinência de saída e posicionada no centro de gravidade do gráfico da função de pertinência. A Fig. 3.13 mostra a simplificação feita no gráfico de saída do exemplo, com o centro de gravidade dado agora por:

$$S = \frac{0,0.10 + 0,2.20 + 0,6.30}{0,0 + 0,2 + 0,6}$$

$$S = 27,5 \text{ min.}$$




Fig. 3.13 - Desfuzificação usando o método de barras verticais.

O método das barras verticais é uma boa aproximação do valor desfuzificado, com a vantagem de diminuir o esforço computacional dos algoritmos.

CAPÍTULO 4

PROCESSO DIFUSO NA CLASSIFICAÇÃO DE CERÂMICAS

4.1 Introdução

Neste capítulo será apresentada uma descrição completa do algoritmo de classificação de cerâmicas lisas usando lógica difusa.

Na seção 4.2 é descrito um sistema de inspeção automático para aplicação na indústria cerâmica. É apresentado um diagrama em blocos onde são mostrados a câmera para aquisição das imagens e o sistema processador, elementos principais dessa estrutura.

O algoritmo de classificação é tratado nas seções seguintes, sendo subdividido em duas etapas: pré-processamento e classificação difusa.

A etapa de pré-processamento, apresentada na seção 4.3, é realizada *off-line* e têm como objetivos a determinação das figuras de mérito que caracterizam as variáveis lingüísticas e os tipos de funções de pertinência usadas na representação das mesmas.

A fase de classificação difusa, executada *on-line*, tem uma estrutura semelhante à ilustrada na Fig. 3.10 (fluxo de dados de um sistema difuso). Seus componentes básicos: *Fuzificação*, *Avaliação de Regras* e *Desfuzificação* são abordados nas seções 4.4 e 4.5.

4.2 Sistema de Inspeção Automático

A Fig. 4.1 mostra a estrutura geral de um sistema de inspeção visual automático aplicado à classificação de cerâmicas. Este sistema é subdividido em três etapas principais: *aquisição, análise e atuação*.

A aquisição é realizada através de uma câmera de estado sólido acoplada a um sistema computadorizado que adquire e armazena as imagens a serem analisadas. Para digitalizar somente da área correspondente à peça cerâmica é necessário um complexo sistema para controlar o campo visual da câmera junto com um dispositivo mecânico de posicionamento do objeto de alta precisão. Esses requisitos, no entanto, além de incrementar desnecessariamente o custo dos subsistemas envolvidos, dificilmente poderão ser realizados em tempo real num sistema automático de inspeção. Assim, a imagem adquirida é composta pelo objeto em estudo (a peça cerâmica) e o fundo.

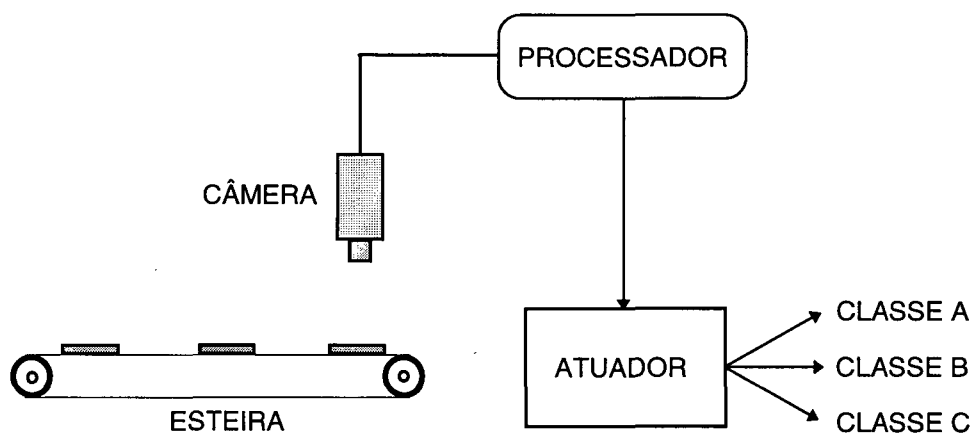


Fig. 4.1 - Estrutura de um sistema de inspeção de cerâmicas automático.

A análise é a fase do processo de inspeção onde se encontra o processamento da informação vinda da etapa de aquisição. O processador pode ser de arquitetura dedicada e os algoritmos devem ter baixa complexidade computacional para tornar possível a implementação da inspeção automática em tempo real.

A análise, na classificação de cerâmicas, subdivide-se em três outras etapas: *segmentação da imagem, análise dos defeitos de borda e análise dos defeitos cosméticos.*

A segmentação usa o histograma da imagem para separar o objeto do fundo e assim fazer a localização dos quatro cantos da cerâmica. A análise dos defeitos de borda verifica se existem cantos quebrados e/ou bordas lascadas [10]. Caso a peça não apresente defeitos nas bordas então aplica-se o algoritmo que faz a análise dos defeitos cosméticos.

Depois de aplicados os algoritmos, a peça é entregue ao atuador. O atuador é um dispositivo mecânico que separa as peças cerâmicas em classes, de acordo com a saída da fase de análise.

Uma vez que se tem uma visão geral do sistema de classificação de cerâmicas, será estudado agora o algoritmo proposto para a análise de defeitos cosméticos.

4.3 Pré-processamento

A primeira etapa do algoritmo de análise dos defeitos cosméticos é o pré-processamento. Nessa fase definem-se todos os elementos com os quais o algoritmo opera: funções de pertinência, variáveis lingüísticas, parâmetros de treinamento, dentre outros. A característica fundamental dessa etapa é que todos seus parâmetros são adquiridos *off-line*.

A primeira preocupação que se tem é utilizar um parâmetro de representação de imagem que não leve a um esforço computacional muito alto e que caracterize bem os defeitos de superfície em cerâmicas lisas.

O componente Intensidade (I), da decomposição em coordenadas HSI (*Hue, Saturation, Intensity*), produz uma imagem em níveis de cinza. Esse componente é representado por uma matriz cujos elementos são *pixels* codificados em 8 *bits* (256 níveis de cinza) que garante um esforço computacional baixo e caracterização completa dos defeitos cosméticos de superfície das peças, não sendo necessário, então, a utilização de imagens coloridas.

4.3.1 Variáveis Lingüísticas

Analisando os defeitos apresentados no Capítulo 2 verifica-se que as cerâmicas lisas podem ter os defeitos de superfície representados por manchas e variação na tonalidade da peça. Verifica-se também que a avaliação pode levar a uma certa imprecisão, já que a natureza dos elementos envolvidos são difíceis de caracterizar. A definição de tamanho de mancha ou o quanto uma determinada peça está fora da tonalidade desejada, por exemplo, certamente poderia conduzir a avaliações errôneas caso fossem usadas variáveis *crisp*.

A tonalidade é a medida da cor da peça na escala de níveis de cinza. Uma peça cerâmica monocromática (lisa) apresenta os valores dos *pixels* da Matriz I próximos entre si. Assim, a média aritmética dos *pixels* da Matriz Intensidade pode representar a tonalidade da peça. Além disso, a variação de tonalidade pode ser avaliada quando a média de uma *peça-amostra* é comparada com a média de uma peça (ou grupo de peças) padrão. Com base nesse padrão diz-se que a *peça-amostra* tem tonalidade mais clara, mais escura ou tem tonalidade próxima.

Os tipos possíveis de manchas em uma cerâmica lisa são *mancha escura*, *mancha aceitável* e *mancha clara*. Essas manchas estão diretamente relacionadas com a tonalidade da peça que representa o fundo da mancha. Uma mancha, em uma cerâmica, gera na imagem uma concentração de *pixels* com variação gradativa até um valor mínimo ou valor máximo. Verificou-se experimentalmente que esse limite, além de estar relacionado com o tamanho e tipo da mancha, posiciona-se aproximadamente na região central da mesma. De acordo com a tonalidade, podem existir manchas claras e/ou escuras. No caso de uma mancha clara os valores de *pixels* crescem gradativamente até um valor máximo. Numa mancha escura os valores de *pixels* têm sua intensidade diminuída até um valor mínimo, como mostrado na Fig. 4.2.

				⋮				
158	159	159	162	156	162	156	157	156
156	158	168	163	157	158	158	160	155
162	156	159	164	148	164	160	161	160
160	158	152	132	76	144	163	156	159
...								...
158	160	153	120	5	117	163	157	161
158	159	158	140	67	113	163	153	160
160	160	160	154	139	143	158	156	158
158	160	159	164	162	158	158	156	160
				⋮				

Fig. 4.2 - Parte da Matriz Intensidade de uma cerâmica lisa com mancha destacada.

Verificando outras manchas observou-se que o valor limite (valor de *pixel* igual a cinco na figura anterior), além de caracterizar o tipo de mancha, tem uma relação com o tamanho da mesma.

Com base no exposto definiram-se as variáveis lingüísticas de entrada MANCHA e TONALIDADE, cada uma delas subdivididas em três valores lingüísticos como mostrado na tabela seguinte:

Tabela 4.1 - Variáveis e valores lingüísticos

Variável Lingüística	Valor Lingüístico		
MANCHA	mancha escura	mancha aceitável	mancha clara
TONALIDADE	tonalidade escura	tonalidade aceitável	tonalidade clara

Ficam também determinadas as figuras de mérito que serão usadas como eixo horizontal das variáveis acima que são a média da Matriz Intensidade (abscissa da variável TONALIDADE) e o valor de *pixel* limite de uma mancha qualquer (abscissa da variável MANCHA).

Os valores lingüísticos centrais (**mancha aceitável** e **tonalidade aceitável**) são muito importantes, pois representam a região da abscissa onde se observa uma característica padrão, tanto para mancha quanto para tonalidade. Considerando esses valores lingüísticos é que serão determinados os elementos numéricos (parâmetros) de fronteira na fase de treinamento.

4.3.2 Treinamento

O objetivo do treinamento é buscar as *fronteiras* (ou *limites*) confiáveis para os valores lingüísticos centrais. Para isso, é selecionado por um inspetor humano experiente um grupo de peças apresentando alta qualidade. Em seguida são adquiridas suas Matrizes I, que serão denotadas aqui por *matrizes-treino*.

Obtêm-se do treinamento quatro valores relacionados com as figuras de mérito apresentadas na subseção anterior.

Para estipular as fronteiras inferior e superior do valor lingüístico **mancha aceitável**, as *matrizes-treino* são varridas na busca do menor e maior valor de *pixel* de cada peça. Esses valores de *pixels* são guardados em dois vetores:

- v_1 : armazena os **menores** valores de *pixels* do grupo de treinamento;
- v_2 : armazena os **maiores** valores de *pixels* do grupo de treinamento.

Os elementos de cada um desses vetores podem ser arranjados de várias maneiras na composição das fronteiras. Adotou-se o menor valor de *pixel* (F_{m1}) do vetor v_1 para a fronteira inferior e o maior valor de *pixel* (F_{m2}) de v_2 para a fronteira superior. Esses valores estão relacionados com a pior mancha escura e a pior mancha clara obtidos do grupo de treinamento, respectivamente.

A **tonalidade aceitável** terá como fronteiras a maior e a menor média das *matrizes-treino*. A menor média (F_{t1}) representa a peça com menor tonalidade e a maior média (F_{t2}) representa a peça de maior tonalidade do grupo de treinamento.

Assim, no final do treinamento, têm-se quatro valores de fronteira:

- F_{m1} : fronteira entre **mancha escura** e **mancha aceitável**;
- F_{m2} : fronteira entre **mancha aceitável** e **mancha clara**;
- F_{t1} : fronteira entre **tonalidade escura** e **tonalidade aceitável**;
- F_{t2} : fronteira entre **tonalidade aceitável** e **tonalidade clara**.

Os gráficos da Fig. 4.3 mostram esses elementos na definição de cada fronteira entre valores lingüísticos adjacentes.




Fig. 4.3 - Fronteiras dos valores lingüísticos centrais.

4.3.3 Funções de Pertinência

As funções de pertinência, definidas no Capítulo 3, devem ser escolhidas com base nas características dos elementos mancha e tonalidade de uma cerâmica. Foram selecionadas três tipos de curvas: *trapezoidal*, *curva "S"* e *sigmoidal*.

4.3.3.1 Curva Trapezoidal

A curva trapezoidal foi selecionada pela sua simplicidade, pois trata-se de uma curva constituída por segmentos de reta. A função de um valor lingüístico central qualquer é dada pela seguinte expressão:

$$\mu_r(x_i) = \begin{cases} \frac{1}{b_t - a_t}(x_i - a_t), & \text{se } a_t \leq x_i \leq b_t \\ 1, & \text{se } b_t \leq x_i \leq c_t \\ \frac{1}{c_t - d_t}(x_i - d_t), & \text{se } c_t \leq x_i \leq d_t \end{cases} \quad \begin{matrix} (4.1a) \\ (4.1b) \\ (4.1c) \end{matrix}$$

A Fig. 4.4 mostra essa curva para o valor lingüístico central.




Fig. 4.4 - Curva de pertinência trapezoidal para valor lingüístico central.

4.3.3.2 Curvas “S”

A curva “S” tem a característica de não-linearidade. Esse fato é importante pois as curvas na região de fronteira (entre o valor lingüístico central e os laterais) devem apresentar valores de derivadas baixas para se estabelecer uma mudança suave entre o valor lingüístico central e seus vizinhos.

Uma expressão comum para formação da função de pertinência “S” [35] é apresentada a seguir.

$$\mu_s = \begin{cases} 0 & , x_i \leq a_s \\ 2 \left[\frac{(x_i - a_s)}{c_s - a_s} \right]^2 & , a_s \leq x_i \leq b_s \\ 1 - 2 \left[\frac{(x_i - c_s)}{c_s - a_s} \right]^2 & , b_s \leq x_i \leq c_s \\ 1 & , x_i \geq c_s \end{cases} \quad (4.2a)$$

$$(4.2b)$$

$$(4.2c)$$

$$(4.2d)$$

Onde o intervalo é $[a_s, c_s]$ e $b_s = \frac{a_s + c_s}{2}$.

Usando a equação (4.2) pode-se obter a função π . Sua expressão é dada por:

$$\mu_\pi = \begin{cases} \mu_s(x_i, a_s, b_s, c_s), & \text{se } x_i \leq c_s \\ 1 - \mu_s(x_i, c_s, b_s', a_s'), & \text{se } x_i \geq c_s \end{cases} \quad (4.3a)$$

$$(4.3b)$$

Onde o intervalo é $[a_s, a_s']$, $c_s = \frac{a_s + a_s'}{2}$, $b_s = \frac{a_s + c_s}{2}$ e $b_s' = \frac{a_s' + c_s}{2}$.

A figura a seguir ilustra as funções “S” e π com os parâmetros que as constituem.




Fig. 4.5 - Funções “S” e π

4.3.3.3 Curva Sigmóide

A função sigmóide apresenta uma curva com forma semelhante à da função “S”. A vantagem de usá-la está no seu traçado mais suave do que a curva “S” na região de fronteira entre dois valores lingüísticos. Sua expressão é dada por:

$$\mu_{SG}(x_i) = \frac{1}{1 + e^{-k(x_i - d_c)}} \quad (4.4)$$

Onde o parâmetro k controla a suavidade com que a curva varia entre os baixos e altos valores de pertinência e d_c é o valor de x_i para $\mu_{SG} = 0,5$. Uma característica importante dessa curva é o fato dela ser assintótica às retas de pertinência zero e um.

A Fig. 4.6 ilustra curvas obtidas a partir da equação (4.4) com variações de k e d_c .

Fica fácil observar que a curva para um valor lingüístico central é obtida usando duas curvas sigmóides simples, com deslocamentos diferentes, sendo aplicado à curva de maior deslocamento o operador complemento. A Fig. 4.7 mostra o formato da função π com curvas sigmóides.




Fig. 4.6 - Curvas sigmóides com variação de k e d_c .




Fig. 4.7 - Curvas sigmóides para valor lingüístico central.

Com o uso das expressões vista e usando ainda o operador complemento é possível obter as curvas para os valores lingüísticos laterais, como mostra a Fig. 4.8.




Fig. 4.8 - Curvas sigmóides para valores lingüísticos central e laterais.

4.3.4 Ajuste das Curvas de Pertinência

O algoritmo deve permitir que o usuário modifique parâmetros de forma a variar o grau de rigor na classificação das peças. Além disso, a quantidade de parâmetros a ser ajustada deve ser a menor possível para garantir simplicidade.

A classificação pode ser alterada pela mudança do grau de pertinência associado a um ponto do domínio das funções. Variando-se a distância entre os pontos de extremidade das funções de pertinência tem-se o efeito desejado. A Fig. 4.9 mostra a expansão do domínio de uma dada curva e seus efeitos no valor de pertinência para um determinado ponto x do domínio dessa função.




Fig. 4.9 - Variação na grau de pertinência de acordo com aumento do domínio da curva.

Ainda na figura anterior, observa-se que a pertinência de x aumenta com a mudança da *curva A* para a *curva B*. Variar o domínio de uma determinada função de pertinência será a forma usada para se ter alteração do rigor da classificação.

Foi definido na subseção 4.3.2 que os valores de fronteira, obtidos do treinamento, estabelecem uma região no domínio da variável lingüística onde se têm as características desejadas para a cerâmica analisada. São esses valores de fronteira relacionados a um determinado grau de pertinência que permitirá a variação das curvas.

Será usada a variável lingüística MANCHA e a curva “S” [35] na dedução da expressão que permitirá o ajuste da curva “S”. A expressão de ajuste para a variável tonalidade pode ser feita de forma análoga. A equação (4.2) é repetida aqui por conveniência.

$$\mu_s = \begin{cases} 0 & , x_i \leq a_s \\ 2 \left[\frac{(x_i - a_s)}{c_s - a_s} \right]^2 & , a_s \leq x_i \leq b_s \\ 1 - 2 \left[\frac{(x_i - c_s)}{c_s - a_s} \right]^2 & , b_s \leq x_i \leq c_s \\ 1 & , x_i \geq c_s \end{cases} \quad \begin{matrix} (4.2a) \\ (4.2b) \\ (4.2c) \\ (4.2d) \end{matrix}$$

Tomando a média de F_{m1} e F_{m2} tem-se definido o parâmetro m_d , ponto da curva “S” onde ocorre a maior pertinência (m_d é equivalente a c_s da equação acima). Assim m_d é dado por:

$$m_d = \frac{F_{m1} + F_{m2}}{2} \quad (4.5)$$

Com base na equação (4.2c) será definida a pertinência de ajuste μ_a (valor de ajuste) que relaciona-se com F_{m1} e F_{m2} e estabelecem-se os parâmetros a_i e a_f (valores *inicial* e *final*, respectivamente), como mostrado na Fig. 4.10.

$$\mu_a(F_{m1}, a_i, m_d) = 1 - 2 \left[\frac{F_{m1} - m_d}{m_d - a_i} \right]^2 \quad (4.6)$$

Isolando o valor de a_i na equação acima, tem-se:

$$a_i = m_d - \frac{m_d - F_{m1}}{\left(\frac{1 - \mu_a}{2} \right)^{1/2}} \quad (4.7)$$

O valor a_f é obtido por simetria em relação a m_d e é dado por:

$$a_f = m_d + (m_d - a_i) \quad (4.8)$$




Fig. 4.10 - Parâmetros usados no ajuste das curvas de pertinência.

A Fig. 4.11 mostra três curvas para o valor lingüístico **mancha aceitável** usando

$F_{m1} = 110$ e $F_{m2} = 150$ para diversos valores de μ_a .




Fig. 4.11 - Curvas de pertinência "S" de **mancha aceitável** com variações de μ_a .

Nas Figs. 4.12 e 4.13 empregou-se a função “S” para compor as variáveis lingüísticas do processo com os valores lingüísticos evidenciados.




Fig. 4.12 - Gráfico de pertinência para variável lingüística MANCHA.




Fig. 4.13 - Gráfico de pertinência para variável lingüística TONALIDADE.

Como foi mencionado as expressões de a_i e a_f são obtidas da função “S”. Com o objetivo de comparar o desempenho das três curvas escolhidas para a classificação, as funções trapezoidal e sigmoidal terão o mesmo intervalo da função o “S” que é: $[a_i, a_f]$. Será mostrado o

processo de posicionamento das curvas trapezoidal e sigmoidal usando, mais uma vez, a variável *mancha* como exemplo.

Caso seja usada a função trapezoidal, o valor lingüístico **mancha aceitável** terá sua reta crescente dada pelos pontos $(a_i, 0)$ e (F_{m1}, μ_a) . Para a equação da reta decrescente têm-se os pontos $(a_f, 0)$ e (F_{m2}, μ_a) . As expressões para a função trapezoidal do valor lingüístico **mancha aceitável** são dadas por:

$$\mu_{tr}(x_i) = \begin{cases} \frac{\mu_a}{F_{m1} - a_i}(x_i - a_i), & \text{se } a_i \leq x_i \leq b_i \\ 1, & \text{se } b_i \leq x_i \leq c_i \\ \frac{\mu_a}{F_{m2} - a_f}(x_i - a_f), & \text{se } c_i \leq x_i \leq a_f \end{cases} \quad (4.9a)$$

$$(4.9b)$$

$$(4.9c)$$

Os valores b_i e c_i podem ser determinados por semelhança de triângulos e são dados por:

$$b_i = \frac{F_{m1} + a_i(\mu_a - 1)}{\mu_a} \quad (4.10)$$

$$c_i = \frac{F_{m2} + a_f(\mu_a - 1)}{\mu_a} \quad (4.11)$$

O posicionamento da função sigmóide é um pouco mais delicado, pois ela é assintótica às retas de pertinência um e zero. Assim, o processo de obtenção de d_c e k parte dos valores já obtidos a_i , a_f e m_d , devendo admitir um *erro* (ϵ) nos pontos acima mencionados.

O parâmetro d_c para a curva crescente do valor lingüístico central será dado por:

$$d_c = \frac{m_d + a_i}{2} \quad (4.12)$$

Para o cálculo do parâmetro k usa-se o fato da curva passar pelo ponto (F_{m1}, μ_a) .

Assim, aplicando esse ponto à equação (4.4) e isolando o valor de k , tem-se:

$$k = \frac{-\ln\left(\frac{1}{\mu_a} - 1\right)}{F_{m1} - d} \quad (4.13)$$

Quando se determinam os parâmetros k e d_c , observando as condições impostas anteriormente, verifica-se que a curva passa por a_i com um valor maior do que zero. Esse erro é independente dos parâmetros de treinamento e acontece também em m_d e a_f (devido à simetria das curvas). Seu valor se altera unicamente pela variação do parâmetro de ajuste μ_a . A curva abaixo mostra os erros observados com a variação do ajuste.




Fig. 4.14 - Gráfico do erro nos pontos a_i , a_f e m_d em função do ajuste μ_a .

O maior erro observado não é crítico, pois os valores de pertinência abaixo de 0,025 representam defeitos quase imperceptíveis.

Com isso têm-se estipulados os parâmetros de qualquer função escolhida tendo como base a função “S”. É importante lembrar que esses parâmetros são determinados *off-line*.

Faz-se necessário aqui alguns comentários a respeito do que foi visto até este ponto:

- i) as funções de pertinência podem ser não simétricas sem prejuízo nenhum com respeito ao desempenho e a complexidade, bastando para isso a escolha de dois valores de ajuste, um associado à curva crescente do valor lingüístico central e outro à curva decrescente;
- ii) a escolha do grupo de treinamento é uma fase de ajuste. Dependendo dessa escolha tem-se maior ou menor rigor na classificação.

4.4 Fuzificação

A fuzificação transforma os valores *crisp*, que são obtidos da Matriz I (ou *matriz-amostra*), em valores de pertinência. Fuzificar, será aqui, associar um defeito a um grau de pertinência que pode assumir qualquer valor entre zero e um. Essa fase é executada *on-line*, o que leva à escolha de estruturas com baixa complexidade computacional.

Na fuzificação da variável TONALIDADE usa-se apenas um valor: a média da *matriz-amostra*.

Para se fuzificar o defeito MANCHA deve-se levar em consideração a presença da pior mancha escura ou clara da peça. Além disso, a forma como as manchas estão espalhadas

deve ser também avaliada já que o efeito visual de um grupo de manchas em uma área pequena na cerâmica leva à classificação diferente da que teria o mesmo grupo de manchas, agora com alta dispersão na cerâmica.

Assim, conclui-se que na fase de fuzificação de manchas está envolvido o maior esforço computacional do algoritmo. Essa etapa será abordada a seguir.

4.4.1 Fuzificação da Variável MANCHA

O processo de fuzificação da variável MANCHA necessita-se percorrer toda a *matriz-amostra* na busca dos defeitos e sua associação a valores de pertinência. Esses defeitos, por sua vez, encontram-se representados na matriz por valores de *pixels* fora do intervalo obtido do treinamento, $[F_{m1}, F_{m2}]$. Assim, a fuzificação ocorrerá somente na região externa a esse intervalo (região de defeitos), reduzindo, com isso, o esforço computacional do processo, já que a maior parte dos valores de *pixels* estão dentro do mencionado intervalo.

A *matriz-amostra* é varrida e caso tenha um valor de *pixel* no intervalo $[0, F_{m1}]$, **mancha escura**, determina-se o valor de pertinência associado e armazena-se esse valor. O mesmo procedimento é usado caso tenha um valor de *pixel* no intervalo $[F_{m2}, 255]$, **mancha clara**. Além dos dois vetores que guardam as pertinências dos valores de *pixels* não pertencentes ao intervalo $[F_{m1}, F_{m2}]$, há necessidade de se armazenar a posição horizontal e vertical desses *pixels* para o cálculo da dispersão das manchas pela peça.

Assim, depois de percorrida toda a matriz, tem-se o seguinte conjunto de vetores:

- m_E : pertinência dos valores dos *pixels* de manchas escuras;
- p_{XE} : posição horizontal dos valores dos *pixels* manchas escuras;
- p_{YE} : posição vertical dos valores dos *pixels* manchas escuras;
- m_C : pertinência dos valores dos *pixels* manchas claras;
- p_{XC} : posição horizontal dos valores dos *pixels* manchas claras;
- p_{YC} : posição vertical dos valores dos *pixels* manchas claras.

Neste ponto do algoritmo os vetores m_E e m_C têm todos os valores de *pixels* de mancha fuzificados. No entanto, vários desses valores de pertinência representam valores de *pixels* de uma mesma mancha. Por exemplo, tem-se parte de uma *matriz-amostra* dada pela Fig. 4.15.

C/L	250	251	252	253	254	255	256	257	258
					⋮				
320	158	159	159	162	156	162	156	157	156
321	156	158	168	163	157	158	158	160	155
322	162	156	159	164	148	164	160	161	160
323	160	158	152	132	76	144	163	156	159
...									...
324	158	160	153	120	5	117	163	157	161
325	158	159	158	140	67	113	163	153	160
326	160	160	160	154	139	143	158	156	158
327	158	160	159	164	162	158	158	156	160
					⋮				

Fig. 4.15 - Parte de uma *matriz-amostra* com mancha destacada e posição dos *pixels* (C/L: coluna/linha).

Supondo que os valores de treinamento são $F_{m1}=130$ e $F_{m2}=170$, tem-se o seguinte resultado da fuzificação dessa parte da *matriz-amostra*:

Valores de *Pixels* :

76	120	5	117	67	113
----	-----	---	-----	----	-----

m_E :

0,5	0,2	0,95	0,22	0,65	0,25
-----	-----	------	------	------	------

p_{XE} :

254	253	254	255	254	255
-----	-----	-----	-----	-----	-----

p_{YE} :

323	324	324	324	325	325
-----	-----	-----	-----	-----	-----

Observando os vetores acima, conclui-se que apenas o menor valor de *pixel*, *pixel* central, deve ser considerado na sequência do algoritmo, mas cinco outros pertencentes à mesma mancha foram armazenados. Com isso, é necessário um algoritmo para eliminar esses elementos não-desejáveis, pois a presença deles inviabiliza o cálculo da dispersão de manchas.

Para eliminar *pixels* não-desejáveis foi estabelecido uma distância limite, abaixo da qual dois *pixels* são considerados como pertencentes à mesma mancha. O algoritmo completo para eliminação de valores de *pixels* de mesma mancha é descrito no Apêndice A.

4.4.1.1 Dispersão de Manchas

A percepção humana é capaz de diferenciar o grau de qualidade de cerâmicas baseado na posição relativa de suas manchas e/ou grupo de manchas. Manchas próximas causam uma sensação de defeito maior do que as mesmas afastadas. Assim, o algoritmo de classificação deve incorporar a medida desse efeito na fuzificação da variável MANCHA.

Como já foi mencionado, uma mancha é representada pelo seu valor de *pixel* central e tem associado a si, um grau de pertinência e as posições horizontal e vertical.

Um determinado tipo de manchas pode-se encontrar de duas formas em uma cerâmica: formando grupos e/ou espalhadas pela peça.

Manchas que encontram-se espalhadas por toda a superfície de uma cerâmica definem a *dispersão global*. Já um grupo de manchas em uma pequena área estabelecem uma *dispersão local*.

Um grupo de manchas de dispersão local é definido como sendo um conjunto de duas ou mais manchas cuja distância entre si é menor que uma distância limite estabelecida. O algoritmo que separa o grupo de manchas com dispersão global e os grupos com dispersão local é apresentado no Apêndice B.

Assim, as dispersões locais e/ou global são utilizadas para formar um grau de pertinência qualitativamente mais próximo do defeito apresentado por uma peça cerâmica.

A dispersão é calculada para todos os grupos detectados. Supondo um grupo genérico, com a presença de N manchas, define-se a *dispersão* pela seguinte expressão:

$$\delta = \sqrt{\sigma_x^2 + \sigma_y^2} \quad (4.14a)$$

onde

$$\sigma_x = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (4.14b)$$

$$\sigma_y = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2} \quad (4.14c)$$

Das expressões acima, têm-se os seguintes elementos:

- x_i : representa a posição horizontal do valor do *pixel* central da *i*-ésima mancha;
- y_i : representa a posição vertical do valor do *pixel* central da *i*-ésima mancha;
- \bar{x} : representa a média dos elementos do vetor posição horizontal;
- \bar{y} : representa a média dos elementos do vetor posição vertical;

Usando as expressões acima, calcula-se a dispersão global, δ_G e as dispersões locais. A *i*-ésima dispersão local é representada por δ_{Li} .

A dispersão é um valor *crisp* e para poder avaliá-la é necessário fazer sua fuzificação. Observa-se pelas equações acima que o valor de dispersão, seja local ou global, é tanto menor quanto maior é o grau de proximidade entre as manchas. Então, dispersão zero define o grau de pertinência 1 (limite inferior). Por outro lado, o valor de dispersão tende a um valor limite quando as manchas encontram-se afastadas (limite superior). Nessa situação associa-se o grau de pertinência zero.

4.4.1.2 Dispersão Limite

A *dispersão limite* é determinada experimentalmente e está relacionada com o número de manchas presentes e com uma fronteira de posicionamento das mesmas.

O limite físico da cerâmica estabelece um valor máximo de dispersão. Assim, o cálculo da *dispersão limite global* δ_L é feito distribuindo as manchas globais detectadas na peça,

de forma equidistante, sobre uma circunferência inscrita na cerâmica. O diâmetro dessa circunferência (L) é igual o limite físico da peça e o valor de pertinência para a dispersão, nessa situação, é considerada insignificante.

A Fig. 4.16 mostra a distribuição de doze manchas globais ($N=12$) pela circunferência inscrita na região de uma peça onde é feito a análise dos defeitos cosméticos.

Nessa mesma figura têm-se também os elementos que caracterizam a posição horizontal e vertical de uma das manchas.




Fig. 4.16 - Distribuição de manchas por uma circunferência para cálculo da dispersão limite global.

Observa-se, pela Fig. 4.16, que as médias horizontal e vertical são zero. Tomando-se um elemento qualquer nessa circunferência, tem-se a seguinte expressão genérica para as dispersão limite:

$$\delta_L = \sqrt{\sigma_{Lx}^2 + \sigma_{Ly}^2} \quad (4.15a)$$

onde

$$\sigma_{Lx} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N r^2 \cos^2 \theta_i} \quad (4.15b)$$

$$\sigma_{Ly} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N r^2 \sin^2 \theta_i} \quad (4.15c)$$

Aplicando σ_{Lx} e σ_{Ly} à equação (4.15a), obtém-se:

$$\delta_L = r \sqrt{\frac{N}{N-1}} \quad (4.16)$$

Caso seja considerado $N \gg 1$, tem-se $\delta_L \cong r$ ou $\delta_L \cong L/2$. Usando $N = 50$, verificou-se que resulta em um bom valor para dispersão limite.

O mesmo procedimento é usado na definição de dispersão limite local. Usa-se uma circunferência de raio de 25 *pixels*. Esse raio é igual à distância limite para estabelecimento de um grupo local (ver Apêndice B).

A Fig. 4.17 mostra a distribuição de manchas locais do *i*-ésimo grupo em uma circunferência de raio de 25 *pixels*.

O cálculo da dispersão limite local δ_{Li} é obtido com o uso das mesmas equações anteriores.




Fig. 4.17 - Distribuição de manchas por uma circunferência para cálculo da dispersão limite local.

4.4.1.3 Fuzificação da Dispersão

Com os dois pontos das extremidades definidos, deve-se escolher, agora, uma curva que melhor se ajuste à tarefa de fuzificar a dispersão. A função sigmoideal será usada para obtenção dessa curva, pois ela apresenta baixos valores de pertinência próximo da dispersão limite o que é interessante devido à aproximação feita ao se definir dispersão limite com base em manchas distribuídas em uma circunferência. A Fig. 4.18 mostra as curvas que permitem a fuzificação da dispersão de manchas em uma peça cerâmica. A equação (4.17) permite a fuzificação da dispersão global. A dispersão local é fuzificada através de uma expressão semelhante usando os parâmetros k_d e δ_{Li} .

$$\mu_D = 1 - \frac{1}{1 + e^{-k_D(\delta - \delta_L/2)}} \quad (4.17)$$




Fig. 4.18 - Curvas de pertinência para dispersão de manchas (global e local)

Como a função sigmoidal é assintótica para as pertinências zero e um, o parâmetro k_D é buscado de forma iterativa até que a função no ponto δ_L seja menor do que um dado erro estabelecido experimentalmente e assumido como sendo $\varepsilon = 0,001$. O mesmo é adotado para dispersão local.

Assim, é definido μ_D como sendo o valor de pertinência para dispersão global e μ_{di} como sendo o valor de pertinência para dispersão local do i -ésimo grupo de manchas.

As expressões a seguir, são responsáveis pela montagem da pertinência final de um tipo de mancha (claras ou escuras).

Se existirem manchas globais e N_c grupos de manchas locais, tem-se:

$$\mu_M = \min \left[\mu_{MAX} + \frac{\sum_{i=1}^{N_c} (n_{di} \mu_{di}) + n_D \mu_D}{N_c + 1}, 1 \right] \quad (4.18)$$

Se existir apenas um grupo de manchas locais ($N_c = 1$), tem-se:

$$\mu_M = \min[\mu_{MAX} + n_d \mu_d, 1] \quad (4.19)$$

Se existir apenas o grupo global ($N_c = 0$), tem-se:

$$\mu_M = \min[\mu_{MAX} + n_D \mu_D, 1] \quad (4.20)$$

Os parâmetros que compõem essas expressões são a seguir descritos:

- μ_M : pertinência final do grupo de manchas claras ou escuras;
- μ_{MAX} : maior valor de pertinência obtido do grupo de manchas claras ou escuras;
- n_D : média dos valores de pertinência observados no grupo global;
- μ_D : pertinência de dispersão global de manchas claras ou escuras.
- n_{di} : média dos valores de pertinência observados no i-ésimo grupo local;
- μ_{di} : pertinência de dispersão do i-ésimo grupo local de manchas claras ou escuras.

Com isso, os valores mancha escura ou mancha clara são ponderados levando-se em conta a pertinência mais representativa (μ_{MAX}) e as dispersões local e global das manchas detectadas. Os parâmetros n_D e n_{di} ajustam, respectivamente, o peso dado à dispersão global e local de forma automática. Caso tenha-se, por exemplo, duas peças, cada uma com um grupo de manchas escuras espalhadas, um desses grupos tem suas manchas com valores de pertinência altos e o outro com manchas de pertinência baixas. Supondo que esses dois grupos tenham mesma

dispersão, o grupo que apresenta maiores valores de pertinência e, conseqüentemente, maior n_d , causa uma sensação de defeito maior do que o grupo de menores valores de pertinência. O mesmo vale para dispersão global.

4.4.1.4 Exemplo de Fuzificação da Variável Mancha

Aqui será feito um exemplo para mostrar o processo de fuzificação da variável MANCHA. Supondo uma peça cerâmica, contendo manchas escuras e claras em distribuição global, como mostra a Fig. 4.19. Nela tem-se também a circunferência inscrita relacionada com a dispersão limite.




Fig. 4.19 - Peça cerâmica com presença de mancha escuras e claras.

Depois de varrida a *matriz-amostra*, têm-se os seguintes vetores:

$$m_E : \begin{array}{|c|c|c|c|c|} \hline 0,6 & 0,15 & 0,3 & 0,05 & 0,65 \\ \hline \end{array}$$

$$p_{XE} : \begin{array}{|c|c|c|c|c|} \hline 400 & 200 & 300 & 250 & 450 \\ \hline \end{array}$$

$$p_{YE} : \begin{array}{|c|c|c|c|c|} \hline 250 & 320 & 380 & 480 & 470 \\ \hline \end{array}$$

$$m_C : \begin{array}{|c|c|c|} \hline 0,15 & 0,2 & 0,1 \\ \hline \end{array}$$

$$p_{XC} : \begin{array}{|c|c|c|} \hline 100 & 585 & 105 \\ \hline \end{array}$$

$$p_{YC} : \begin{array}{|c|c|c|} \hline 100 & 270 & 480 \\ \hline \end{array}$$

A Fig. 4.20 mostra a curva de pertinência ajustada para a obtenção do nível de pertinência de dispersão das manchas escuras e também alguns parâmetros do processo inclusive a dispersão limite, obtida com base em **cinco** manchas espalhadas de forma equidistante em uma circunferência de raio 300 *pixels*.




Fig. 4.20 - Curva de pertinência para dispersão das manchas escuras.

Usando o procedimento descrito anteriormente, têm-se os seguintes resultados para o conjunto de manchas escuras:

- Máxima pertinência obtida do grupo: $\mu_{MAX} = 0,65$;
- Média dos valores de pertinências observados no vetor m_E : $n_D = 0,35$;
- Dispersão calculada: $\delta = 142$;
- Pertinência de dispersão: $\mu_D = 0,72$;
- Pertinência final do grupo: $\mu_M = 0,902$;

Da mesma forma tem-se, a seguir, uma figura com o gráfico da função de pertinência usada na fuzificação da dispersão das manchas claras e alguns de seus parâmetros, inclusive a dispersão limite, resultado do espalhamento de três manchas por uma circunferência de raio 300 *pixels* posicionadas de forma equidistante.




Fig. 4.21 - Curva de pertinência para dispersão das manchas claras.

Os resultados obtidos para o conjunto de manchas claras são apresentados a seguir:

- Máxima pertinência obtida do grupo: $\mu_{MAX} = 0,2$;
- Média dos valores de pertinências observados no vetor m_C : $n_D = 0,16$;
- Dispersão calculada: $\delta = 335$;
- Pertinência de dispersão: $\mu_D = 0,05$;
- Pertinência final do grupo: $\mu_M = 0,208$.

Para tornar coerente a fuzzificação da variável MANCHA, usando três valores lingüísticos é necessário que pelo menos um desses valores de extremidade (**mancha escura** ou **mancha clara**) tenha pertinência igual a zero. Assim, será tomado o maior deles, fixando o outro no nível de pertinência zero. O valor lingüístico **mancha aceitável** tem seu valor determinado pelo complemento do valor lingüístico adjacente diferente de zero. É importante observar que não existe, nessa etapa do algoritmo, relação entre as funções de pertinência e os valores de pertinência finais obtidos devido às modificações inseridas pela dispersão.

Usando o exemplo, tem-se a seguinte síntese de valores correspondentes à variável lingüística MANCHA:

- Valor de pertinência de **mancha escura**: $\mu_{ME} = 0,902$;
- Valor de pertinência de **mancha aceitável**: $\mu_{MN} = 0,098$;
- Valor de pertinência de **mancha clara**: $\mu_{MC} = 0,000$;

4.4.2 Fuzificação da Variável TONALIDADE

Como foi discutido, a fuzificação da variável TONALIDADE é feita com facilidade pois obtém-se apenas um valor *crisp* para cada *matriz-amostra: média da matriz*. Essa média é posicionada no domínio da variável lingüística em questão e obtidos os valores de pertinência para os três valores lingüísticos definidos. No final da fuzificação dessa variável, tem-se três valores de pertinência, observando que pelo menos um deles é igual a zero.

Supondo que a matriz obtida da peça da Fig. 4.22 apresenta média igual a 150, tem-se o gráfico abaixo que mostra o processo de obtenção dos valores de pertinência usando as curvas “S”.




Fig. 4.22- Fuzificação da variável TONALIDADE.

Com base na figura anterior tem-se os seguintes valores de pertinência:

- Valor de pertinência de **tonalidade escura**: $\mu_{TE} = 0,00$
- Valor de pertinência de **tonalidade aceitável**: $\mu_{TN} = 0,89$
- Valor de pertinência de **tonalidade clara**: $\mu_{TC} = 0,11$

4.5 Desfuzificação

O processo convencional dos algoritmos difusos é composto pelas fases de *Fuzificação, Avaliação de Regras e Desfuzificação*.

O etapa de fuzificação foi abordada na seção anterior com as modificações necessárias devido à natureza da aplicação.

Na fase de avaliação de regras busca-se, através de regras, a ponderação dos valores lingüísticos de saída (*consequentes*) por meio dos valores lingüísticos de entrada vindos da etapa de fuzificação (*antecedentes*).

Os valores de saída são passados ao processo de desfuzificação que define o valor *crisp* de saída através da *Regra do Centróide* ou *Centro de Gravidade* (ver Capítulo 3).

A metodologia convencional de algoritmo difuso não se mostrou apropriada devido à complexidade de projeto e à complexidade computacional apresentadas. É proposto então um procedimento de desfuzificação para viabilidade do algoritmo em tempo real.

Nesta seção será abordada a metodologia convencional e a nova metodologia empregada para a transformação dos valores de pertinência, referentes aos defeitos cosméticos, para as classes de saída que se deseja, definidas como: *Classe A*, *Classe B* e *Classe C*.

4.5.1 Processo de Desfuzificação Convencional

A fase de avaliação de regras é onde os valores lingüísticos são confrontados para se produzir alguns níveis de saída. Uma regra de inferência é composta de antecedente(s) e

conseqüente(s). A forma como os antecedente(s) e conseqüente(s) combinam-se para formar os graus de pertinência dos valores lingüísticos de saída é chamada inferência. Os métodos de inferência mais usuais são:

- i) *Max-Min* [30]: nesse método os conseqüentes são compostos pelo *mínimo* entre os antecedentes (operador interseção) e as entradas da fase de desfuzificação pelo *máximo* dos conseqüentes (operador união).
- ii) *Max-Produto* [30]: nesse método os conseqüentes são compostos pelo *produto* entre os antecedentes e as entradas da fase de desfuzificação pelo *máximo* dos conseqüentes.

O confronto entre as variáveis MANCHA e TONALIDADE gera três valores lingüísticos distribuídos em nove regras. Para efeito de exemplo, os valores lingüísticos de saída serão tomados como sendo **boa**, **regular** e **ruim**.

Uma regra exemplo, usando inferência *Max-Min*, pode ser dada por:

IF **mancha escura**(μ_{ME}) AND **tonalidade escura**(μ_{TE})

THEN saída = **ruim**(μ_{ruim})

Contudo, todas as regras podem ser resumidas numa tabela onde consta os valores lingüísticos em confronto (antecedentes) e os valores lingüísticos de saída (conseqüentes).

Tabela 4.2- Regras de Inferência

///	mancha escura	mancha aceitável	mancha clara
tonalidade escura	ruim	regular	ruim
tonalidade aceitável	regular	boa	regular
tonalidade clara	ruim	regular	ruim

Observando a tabela anterior têm-se quatro valores de pertinência para a saída **ruim**, quatro para a saída **regular** e um para a saída **boa**. Baseado na inferência *Max-Min*, tomando-se o maior grau de pertinência para cada valor lingüístico. Os valores são então passados à próxima fase do algoritmo, que é a desfuzificação.

Na fase de desfuzificação são montadas curvas de pertinência e as saídas *crisp* são dispostas no domínio dessas curvas.

O objetivo é ter três classes de saída: Classe A (agrupa cerâmicas sem defeito), Classe B (agrupa cerâmicas com pequenos defeitos) e Classe C (agrupa cerâmicas defeituosas).

Uma possível curva para desfuzificação é a triangular. A Fig. 4.23 mostra curvas de saída triangulares com um possível posicionamento das classes de saída.




Fig. 4.23 - Curvas triangulares com as classes de saída A, B e C.

Os graus de pertinência de cada valor lingüístico é levado à curva de saída e a classe a qual a cerâmica pertence é indicada pelo centro de gravidade da curva resultante, como mostrado na Fig. 4.24.




Fig. 4.24 - Processo de desfuzificação usando centro de gravidade.

O processo descrito apresenta uma grande complexidade de projeto devido, principalmente, a dois pontos fundamentais:

- i) A escolha do formato das curvas de desfuzificação;
- ii) O posicionamento das classes de saída no domínio das curvas de pertinência.

O ajuste desses dois pontos é experimental, podendo resultar em um formato de curva qualquer (não simétrico), com qualquer posição para as classes A, B e C.

Devido a esses problemas houve necessidade de buscar uma outra solução, adaptando as fases de Avaliação de Regras e Desfuzificação à aplicação específica de classificar cerâmicas.

4.5.2- Processo de Desfuzificação Simplificado

O processo de obtenção das classes de saída (A, B e C), a partir dos defeitos fuzzificados, pode ser bastante simplificado numa conversão direta de setores de pertinência para classes de saída.

Por *setor de pertinência* entende-se um intervalo no contradomínio das funções de pertinência. O tamanho do intervalo está diretamente relacionado com o grau de resolução da classificação.

Sucessivas simulações mostraram que a subdivisão do intervalo $[0,1]$ em dez setores, fornece resolução suficiente para o processo de classificação de cerâmicas. A Fig. 4.25 ilustra essa subdivisão.




Fig. 4.25 - Divisão do contradomínio em setores.

Com essa técnica de setorização dos níveis de pertinência tem-se a versatilidade de se obter grande precisão, empregando alta resolução nas faixas de pertinência onde existe maior dificuldade de decisão na definição de qual classe deve ser a saída.

Como se têm sempre curvas de pertinência complementares, não há necessidade de usar todos os valores lingüísticos fuzzificados. Perde-se a informação de qual defeito ocorreu mas, obtém-se uma menor complexidade. Optou-se por usar o valor lingüístico lateral diferente de zero para mancha e tonalidade, já que estes carregam em si toda a informação do defeito presente. Assim, são definidos os valores **mancha**(μ_M) e **tonalidade**(μ_T), que representam os valores lingüísticos laterais com grau de pertinência diferente de zero. Cada um desses valores é disposto numa determinada posição da tabela (linha ou coluna).

Assim, dispondo o valor lingüístico **mancha**(μ_M) na vertical (colunas) e o valor **tonalidade**(μ_T) na horizontal (colunas), obtém-se uma matriz 10×10 cujos elementos são as classes de saída (A, B ou C).

Duas foram as informações consideradas quando do preenchimento da tabela de saída:

- a relação entre setor de pertinência e intensidade do defeito;
- a composição da saída através do setor que representa **mancha** e o setor que representa **tonalidade**.

Esse procedimento é análogo ao processo de avaliação de regras, pois considerando o setor, avalia-se o grau de pertinência dos valores lingüísticos. O mesmo se faz nos processos de inferência (*Max-Min* e *Max-Produto*). Depois de se avaliar o setor e saber o grau de defeito da peça com relação a mancha e tonalidade, considera-se essas duas informações para decisão de qual classe terá a saída. A mesma situação acontece numa regra de inferência onde o

Definidas para uma cerâmica a ser classificada os graus de pertinência para os valores lingüísticos **mancha**(μ_M) e **tonalidade**(μ_T), a tabela anterior é aplicada da seguinte forma:

- define-se o setor do valor mancha aceitável (S_M);
- define-se o setor do valor tonalidade aceitável (S_T);
- localiza-se a posição (S_T, S_M) = (linha, coluna) que fornece a classe de saída.

O processo de desfuzificação simplificado pode ser otimizado através dos seguintes passos:

- i) subdivide-se do contradomínio das funções de pertinência num certo número de setores (o número de setores está diretamente relacionado à resolução do processo de classificação);
- ii) determina-se a qual setor pertence o grau de pertinência μ_M ;
- iii) determina-se a qual setor pertence o grau de pertinência μ_T ;
- iv) consulta-se um especialista em classificação de cerâmicas para dizer a que classe de saída a peça pertence;
- v) repete-se os passo (ii) ao (iv) até finalizar o lote de cerâmicas disponível para montagem da tabela de desfuzificação;
- vi) decidir (usualmente através de métodos estatísticos) a que classe de saída corresponde cada uma das células da *matriz de desfuzificação*;

Como visto, o processo de desfuzificação simplificado tira proveito do conhecimento de um especialista em classificação de cerâmica na montagem de uma tabela de saída otimizada. Além disso, esse especialista não necessita, para tal, ter qualquer conhecimentos de lógica difusa.

No processo de desfuzificação convencional, o especialista em lógica difusa deve também ser especialista em classificação de cerâmicas, sendo capaz de classificar as peças e também escolher e ajustar as curvas para o algoritmo de classificação.

CAPÍTULO 5

RESULTADOS EXPERIMENTAIS

5.1 Introdução

No presente capítulo são apresentados os principais resultados obtidos da classificação de dois grupos de cerâmicas usando o algoritmo proposto.

Cada um desses grupos foi subdividido, via inspeção manual, em dois outros grupos:

- *Cerâmicas Aceitadas;*
- *Cerâmicas Rejeitadas.*

As Cerâmicas Aceitadas pertencem à Classe A. Já as Cerâmicas Rejeitadas pertencem à Classe C. A Classe B é constituída de peças com defeitos, tais que as tornam de qualidade intermediária.

O primeiro grupo, denotado por Grupo I, é constituído de 165 peças lisas claras. Um exemplo de cerâmica do Grupo I é ilustrado no Capítulo II através da Fig. 2.1 . O grupo de *Cerâmicas Aceitadas* é formado de 150 peças e o grupo de *Cerâmicas Rejeitadas* por 15 peças.

O segundo grupo, denotado por Grupo II, é constituído de 25 *Cerâmicas Aceitadas* e 13 *Cerâmicas Rejeitadas*. Um exemplo de cerâmica do Grupo II é ilustrado no Capítulo 2 pela Fig. 2.6 .

5.2 Grupos de Treinamento

Os grupos de treinamento são montados com base nas *Cerâmicas Aceitadas*, sejam elas pertencentes ao Grupo I ou ao Grupo II.

Para o Grupo I foram usadas 30 cerâmicas como grupo de treinamento, resultando nas fronteiras dadas pela Tabela 5.1.

Tabela 5.1 - Fronteiras de treinamento para o Grupo I.

/////	MANCHA	TONALIDADE
F_{m1}	132	--
F_{m2}	172	--
F_{t1}	--	151,03
F_{t2}	--	162,85

Para o Grupo II foram usadas apenas 5 cerâmicas como grupo de treinamento, resultando nas fronteiras dadas pela Tabela 5.2.

Tabela 5.2 - Fronteiras de treinamento para o Grupo II.

/////	MANCHA	TONALIDADE
F_{m1}	13	--
F_{m2}	136	--
F_{t1}	--	20
F_{t2}	--	66

5.3 Parâmetros de Ajuste

Para ajustar o rigor de classificação faz-se uso dos parâmetros de ajustes μ_{am} e μ_{at} , relacionados com os defeitos manchas e desvios de tonalidade, respectivamente. É interessante observar que cada tipo de cerâmica pode apresentar um determinado conjunto de parâmetros de ajuste, apesar de se obter para os Grupos I e II parâmetros bem próximos.

A Tabela 5.3 apresenta os parâmetros de ajuste, definidos experimentalmente, para os grupos usados nas simulações.

Tabela 5.3 - Parâmetros de ajuste usados nas simulações.

/////	GRUPO I	GRUPO II
μ_{am}	0,95	0,95
μ_{at}	0,90	0,91

5.4 Resultados

5.4.1 Resultados do Grupo I

As tabelas a seguir resumem os resultados da classificação para as curvas de pertinência trapezoidal, “S” e sigmoidal.

O grupo Cerâmicas Aceitadas (150 peças), consideradas sem defeitos, apresentaram os seguintes resultados percentuais:

Tabela 5.4 - Classificação usando curva trapezoidal (Boas: Grupo I).

Curva Trapezoidal		
Classe A	Classe B	Classe C
96,7%	3,3%	0,0%

Tabela 5.5 - Classificação usando curva “S” (Boas: Grupo I).

Curva “S”		
Classe A	Classe B	Classe C
96,7%	3,3%	0,0%

Tabela 5.6 - Classificação usando curva sigmoidal (Boas: Grupo I).

Curva Sigmoidal		
Classe A	Classe B	Classe C
96,7%	3,3%	0,0%

O grupo de *Cerâmicas Rejeitadas* foi montado com 15 peças que apresentam vários tipos de defeitos (manchas e variações de tonalidades). A seguir é apresentado o resultado do algoritmo para esse grupo de cerâmicas.

Tabela 5.7 - Classificação usando curva trapezoidal (Ruins: Grupo I).

Curva Trapezoidal		
Classe A	Classe B	Classe C
0,0%	6,7%	93,3%

Tabela 5.8 - Classificação usando curva “S” (Ruins: Grupo I).

Curva “S”		
Classe A	Classe B	Classe C
0,0%	0,0%	100,0%

Tabela 5.9 - Classificação usando curva sigmoidal (Ruins: Grupo I).

Curva Sigmoidal		
Classe A	Classe B	Classe C
0,0%	0,0%	100,0%

5.4.2 Resultados do Grupo II

Usando as curvas trapezoidal, “S” e sigmoidal, para o grupo de *Cerâmicas Aceitadas* (20 peças),obtem-se os seguintes resultados.

Tabela 5.10 - Classificação usando curva trapezoidal (Boas: Grupo II).

Curva Trapezoidal		
Classe A	Classe B	Classe C
100,0%	0,0%	0,0%

Tabela 5.11 - Classificação usando curva “S” (Boas: Grupo II).

Curva “S”		
Classe A	Classe B	Classe C
92,0%	8,0%	0,0%

Tabela 5.12 - Classificação usando curva sigmoidal (Boas: Grupo II).

Curva Sigmoidal		
Classe A	Classe B	Classe C
100,0%	0,0%	0,0%

O grupo de *Cerâmicas Rejeitadas* (13 peças), apresentando peças com manchas e/ou variação na tonalidade, levaram à seguinte classificação:

Tabela 5.13 - Classificação usando curva trapezoidal (Ruins: Grupo II).

Curva Trapezoidal		
Classe A	Classe B	Classe C
0,0%	38,5%	61,5%

Tabela 5.14 - Classificação usando curva "S" (Ruins: Grupo II).

Curva "S"		
Classe A	Classe B	Classe C
0,0%	30,8%	69,2%

Tabela 5.15 - Classificação usando curva sigmoidal (Ruins: Grupo II).

Curva Sigmoidal		
Classe A	Classe B	Classe C
0,0%	7,7%	92,3%

5.5 Análise dos Resultados

As simulações foram realizadas buscando sempre a comparação do desempenho das três curvas empregadas.

Com base nesses resultados conclui-se que a curva sigmoidal é a melhor curva para o uso do algoritmo. Apesar disso, a função sigmoidal usada é a que resulta em um maior esforço computacional.

Essa dificuldade pode ser superada com o uso de uma *tabela de fuzificação* onde se teria os níveis de pertinência como elementos associados a valores *crisp* de entrada. Esse procedimento levará a etapa de fuzificação ter uma mesma complexidade computacional, qualquer que seja a curva utilizada.

CAPÍTULO 6

CONCLUSÕES

Esta dissertação propõe um algoritmo para inspeção visual automática aplicado à classificação de cerâmicas lisas.

A metodologia empregada visa um controle de qualidade eficiente, além da compatibilidade entre as velocidades de produção e inspeção.

Está comprovado que o desempenho dos inspetores humanos, atuando em processos de classificação visual, é bastante deficiente para a realização de tarefas rotineiras por longos períodos. Isso significa que eles têm apenas bom desempenho durante parte de sua jornada de trabalho, resultando, portanto, em sérios problemas de classificação de defeitos. Esse é um dos motivos que justifica plenamente o emprego de sistema de inspeção automático, que desempenha seu papel com maior velocidade e de forma constante.

Apesar de se encontrarem disponíveis comercialmente processadores rápidos para permitir aplicações de inspeção *on-line*, um cuidado especial deve-se atribuir aos sistemas de processamento de imagens para operação em tempo real. Esses sistemas devem cumprir um requisito fundamental: os algoritmos devem apresentar baixa complexidade computacional. Implementações simples e de boa precisão podem ser conseguidas quando estão presentes estruturas de baixa complexidade computacional.

O algoritmo desenvolvido neste trabalho está baseado na teoria de Lógica Difusa. Algoritmos empregando lógica difusa têm sido muito aplicados quando há necessidade de manipulação de conceitos indefinidos ou imprecisos. Suas principais ferramentas são as *funções de pertinência* e as *variáveis linguísticas* que, juntas, são capazes de ponderar defeitos em cerâmicas, como a presença de manchas ou variação da tonalidade. Com isso obtém-se um algoritmo que leva a resultados bem próximos das classificações executadas por um inspetor humano experiente.

Outra característica do algoritmo é sua estrutura simples, capaz de levar a uma complexidade computacional relativamente baixa, tornando possível sua aplicação em tempo real.

Os processos clássicos realizam a classificação com apenas duas classes de saída: cerâmicas “aceitadas” e cerâmicas “rejeitadas”. Já o algoritmo proposto pode ter o número de classes de saída aumentado, classes essas que têm associado a si um determinado grau de qualidade. Além disso, o algoritmo permite que o grau de rigor na classificação seja modificado, através de apenas dois parâmetros de ajuste, possibilitando classificações de acordo com a necessidade do usuário.

Assim, características como precisão, simplicidade e versatilidade foram conseguidas através de uma metodologia via lógica difusa, tornando possível o emprego desse algoritmo na indústria cerâmica ou mesmo aplicações em outros tipos de indústrias que apresentem características similares, como, por exemplo, a indústria têxtil ou a indústria de papel.

Uma sugestão para futuros trabalhos é usar as técnicas abordadas aqui, conjugadas com redes neurais com o objetivo de classificar cerâmicas decoradas.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] WANG, C.; BHAT, P.B.; PRASANNA, V.K. High-performance computing for vision. **Proc. IEEE**, v. 84, n. 7, p. 931-946, july 1996.
- [2] ANDREWS, Harry C. **Introduction to mathematical techniques in pattern recognition**. New York: Wiley- Interscience, 1972.
- [3] KENT, E. W. Eyes for automatons, **IEEE Spectrum**, p. 37-45, mar. 1986.
- [4] SHIN, K. G.; RAMANATHAN, P. Real-time computing: a new discipline of computer science and engineering. **Proc. IEEE**, v. 82, n. 1, p. 6-24, jan. 1994.
- [5] PENAFIEL, F; FERNANDEZ, L.; CAMPEY, P. et al. Computer vision system for 3D inspection. **Proc. SPIE - Int. Soc. Opt. Eng.**, v. 2247, p. 15-25, 1994.
- [6] ALCANTUD, J. A. López; CARBONELL, A. Aniorte; ASENSI, G. Doménech et al. Inspection & quality control based on artificial vision techniques for the automation of manufacturing process in the footwear industry. **Second Asin Conf. On Computer vision**, Singapore, 1995.
- [7] BARNI, M.; CAPPELLINI, V.; MECOCCHI, A. A vision system for automatic inspection of meat quality. **Proc. ICIAP'95 Conference**, Sept. 1995.
- [8] SCHOONARD, J. W.; GOULD, J. D. Field of view and target uncertainty in visual search and inspection. **Human Factors**, feb. 1973.
- [9] WANG, S. C. Human reliability in visual inspection. **Quality**, sept. 1974.

- [10] TOBIAS, Orlando J. **Inspeção visual automática baseada na análise de texturas**. Florianópolis, 1995. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Santa Catarina.
- [11] HARALICK, R. M. Statistical and structural approaches to texture. **Proc. IEEE**, v. 67, n. 5, p. 786-804.
- [12] TAMURA, H.; MORI, S.; YAMAWAKI, T. Textural features corresponding to visual perception. **IEEE Trans. Syst., Man, Cybern**, v. SMC-8, n. 6, p. 460-473, june 1978.
- [13] BEZDEK, James C. Fuzzy models - what are they, and why? **IEEE Trans. Fuzzy Sets**, v. 1, n. 1, p. 1-6, feb. 1993.
- [14] ZADEH, Lotfi A. Fuzzy logic = computing with words. **IEEE Fuzzy Syst.**, v. 4, n. 2, p. 103-111, may 1996.
- [15] ZADEH, Lotfi A. Making computers think like people. **IEEE Spectrum**, p. 26-32, aug. 1984.
- [16] ZADEH, Lotfi A. Fuzzy sets. **Inform. Control**, v. 8, p. 338-353, 1965.
- [17] SCHWARTZ, D. G.; KLIR, G. J.; LEWIS, H. W. et al. Applications of fuzzy sets and approximate reasoning. **Proc. IEEE**, v. 82, n. 4, p. 482-498, apr. 1994.
- [18] BONISSONE, P. P.; BADAMI, V.; CHIANG, K. H. et al. Industrial applications of fuzzy logic to general electric. **Proc. IEEE**, v. 83, n. 3, p. 450-465, mar. 1995.
- [19] WATANABE, H.; YAKOWENKO, W. J.; KIM, Y. et al. Application of fuzzy discrimination analysis for diagnosis of valvular heart disease. **Trans. Fuzzy Syst.**, v. 2, n. 4, p. 267-276, nov. 1994.

- [20] HESSBURG, T.; TOMIZUKA, M. Fuzzy logic control for lateral vehicle guidance. **IEEE Control Systems**, v. 14, n. 4, p. 55-63, aug. 1994.
- [21] GADER, P.; KELLER, J. M.; CAI, J. A fuzzy logic system for the detection and recognition of handwritten street numbers. **IEEE Trans. Fuzzy Syst.**, v. 3, n. 1, p. 83-95, feb. 1995.
- [22] TRIVEDI, M. M; BEZDEK, James C. Low-level segmentation of aerial images with fuzzy clustering. **IEEE Trans. Syst., Man, Cybern**, v. SMC-16, n. 4, p. 589-598, july/aug. 1986.
- [23] FERNANDES, Anita M. R.; BASTOS, Rogério C. A fuzzy expert system for qualitative chemical analyses of minerals using recognition. **IEEE Proc. ISUMA-NAFIPS**, p. 734-738, 1995.
- [24] LURIA, M.; ADIN, E.; MORAN, M. et al. Automatic defect classification using fuzzy logic. **IEEE/SEMI Advanced Semiconductor Manufacturing Conference**, oct. 1993.
- [25] GATH, I.; GEVA, A. B. Unsupervised optimal fuzzy clustering. **Trans. Pattern. Anal. Machine Intell.**, v. PAMI-11, n. 7, p. 773-781, july 1989.
- [26] BEZDEK, James C.; CASTELAZ, Patrick F. Prototype classification and feature selection with fuzzy sets. **IEEE Trans. Syst., Man, Cybern**, v. SMC-7, n. 2, p. 87-92, feb. 1977.
- [27] MANUAL SACMI. Defeitos. INTRATEC - Traduções Técnicas Ltda.
- [28] KAUFMANN, Arnold. **Introduction to the theory of fuzzy subsets**. Vol. 1, New York: Academic Press, , 1975.
- [29] COX, Earl. **The fuzzy systems handbook**. Cambridge: Academic Press, 1994.

- [30] ZIMMERMANN, Hans-Jürgen. **Fuzzy set theory - and its applications**. 2. ed. Norwell: Kluwer Academic Publishing, 1985.
- [31] ZADEH, Lotfi A. Outline of a new approach to the analysis of complex systems and decision processes. **IEEE Trans. Syst., Man, Cybern.**, v. SMC-3, n. 1, p. 28-44, jan. 1973.
- [32] LAVIOLETTE, M.; SEAMAN Jr, W. The efficacy of fuzzy representations of uncertainty. **IEEE Trans. Fuzzy Syst.**, v. 2, n. 1, p. 4-15, feb. 1994.
- [33] MENDEL, J. M. Fuzzy logic systems for engineering: a tutorial. **Proc. IEEE**, v. 83, n. 3, p. 354-377, mar. 1995.
- [34] BOSE, B. K. Expert system, fuzzy logic, and neural network applications in power electronics and motion control. **Proc. IEEE**, v. 82, n. 8, p. 1303-1323, aug. 1994.
- [35] PAL, Sankar K.; ROSENFELD, A. Image enhancement and thresholding by optimization of fuzzy compactness. **Pattern Recogn. Letters**, v. 7, p. 77-86, feb. 1988.
- [36] CHANDRA, D. V. S. Orientation estimation of industrial parts for automated inspection. **Proc. 36th Midwest Symposium on Circuits and Systems**, v. 2, p. 1436-1438, aug. 1993.

APÊNDICE A

ALGORITMO PARA A DETERMINAÇÃO DO *PIXEL* REPRESENTATIVO DE MANCHAS

A.1 Introdução

Uma mancha em uma *matriz-amostra* afeta vários *pixels*. Como visto no Capítulo 4, seção 4.3.1, existe um *pixel*, posicionado aproximadamente no centro da mancha, que é o elemento que melhor a representa. Os outros *pixels* são indesejáveis caso se queira analisar a dispersão de manchas na peça cerâmica.

O objetivo desse algoritmo é partindo do conjunto de manchas detectadas e fuzificadas e descartar os valores de *pixels* de mesma mancha, bem como suas posições horizontal e vertical.

A.2 Valores de Entrada

Da etapa de fuzificação obtêm-se seis vetores, resultado da presença de manchas escuras e claras. Esses vetores serão repetidos aqui por conveniência:

- m_E : pertinência dos valores dos *pixels* de manchas escuras;
- p_{XE} : posição horizontal dos valores dos *pixels* manchas escuras;
- p_{YE} : posição vertical dos valores dos *pixels* manchas escuras;
- m_C : pertinência dos valores dos *pixels* manchas claras;
- p_{XC} : posição horizontal dos valores dos *pixels* manchas claras;
- p_{YC} : posição vertical dos valores dos *pixels* manchas claras.

O algoritmo para a determinação do *pixel* mais representativo de manchas vai ser mostrado usando um conjunto de manchas escuras. Para um conjunto de N manchas escuras têm-se os seguintes vetores:

$$m_E = [\mu_{E1} \quad \mu_{E2} \quad \mu_{E3} \quad \dots \quad \mu_{E_N}]$$

$$p_{xE} = [x_{E1} \quad x_{E2} \quad x_{E3} \quad \dots \quad x_{E_N}]$$

$$p_{yE} = [y_{E1} \quad y_{E2} \quad y_{E3} \quad \dots \quad y_{E_N}]$$

A.3 Passos do Algoritmo

Passo 1:

a) ordenar o vetor m_E de forma decrescente criando o vetor M ;

b) ordenar os vetores p_{xE} e p_{yE} criando os vetores P_x e P_y , respectivamente, cujos elementos são indexados aos elementos de M ;

$$M = [\mu_1 \quad \mu_2 \quad \mu_3 \quad \dots \quad \mu_N]$$

$$P_x = [x_1 \quad x_2 \quad x_3 \quad \dots \quad x_N]$$

$$P_y = [y_1 \quad y_2 \quad y_3 \quad \dots \quad y_N]$$

onde

- μ_1 : maior pertinência de M ;
- μ_N : menor pertinência de M ;
- x_1 : posição horizontal indexada à μ_1 ;
- y_1 : posição vertical indexada à μ_1 ;
- x_N : posição horizontal indexada à μ_N ;
- y_N : posição vertical indexada à μ_N .

Passo 2:

Cálculo da distância entre dois pontos usando os vetores P_x e P_y e comparação com a distância limite $d = 10$ pixels e formação de novos vetores com pixels indesejáveis retirados. A função $tamanho(M)$ fornece um número de elementos de M .

a) Faça $i = 1$; {primeiro ponto = (x_1, y_1) }

b) Enquanto i menor que $tamanho(M)$ faça

1) Para j de 1 até i faça {primeiros elementos dos vetores auxiliares}

$$M_{AUX}(j) = M(j);$$

$$P_{xAUX}(j) = P_x(j);$$

$$P_{yAUX}(j) = P_y(j);$$

Fim do Para. {valores já comparados + o valor a ser comparado}

2) Faça $m = i + 1$; {próximo elemento a ser colocado nos vetores auxiliares}

3) Para n de $(i + 1)$ até $tamanho(M)$ faça

$$\text{Se } \sqrt{(x_i - x_n)^2 + (y_i - y_n)^2} > 10 \quad \{ x_i \text{ e } x_n \in a P_x, y_i \text{ e } y_n \in a P_y \}$$

Então faça

$$M_{AUX}(m) = \mu_n; \{ \mu_n \in a M \}$$

$$P_{xAUX}(m) = x_n;$$

$$P_{yAUX}(m) = y_n;$$

Faça $m = m + 1$; { incremento de m }

Fim do Se.

Fim do Para.

4) Faça

$$M = M_{AUX};$$

$$P_x = P_{xAUX};$$

$$P_y = P_{yAUX};$$

Apague os vetores M_{AUX} , P_{xAUX} e P_{yAUX} .

5) Incremente i ;

Fim do Enquanto;

Fim do Algoritmo.

ELEMENTOS DE SAÍDA:

M : Vetor mancha reduzido;

P_x : Vetor posição horizontal reduzido;

P_y : Vetor posição vertical reduzido;

A.4 SIMULAÇÃO

Sejam os vetores, resultados de fuzificação de uma *matriz-amostra*, dados por:

$M:$	0,9	0,85	0,5	0,3	0,25	0,1
------	-----	------	-----	-----	------	-----

$P_x:$	300	400	500	405	305	505
--------	-----	-----	-----	-----	-----	-----

$P_y:$	300	400	500	405	305	505
--------	-----	-----	-----	-----	-----	-----

$i = 1$

$M:$	0,9	0,85	0,5	0,3	0,1
------	-----	------	-----	-----	-----

$P_x:$	300	400	500	405	505
--------	-----	-----	-----	-----	-----

$P_y:$	300	400	500	405	505
--------	-----	-----	-----	-----	-----

$i = 2$

$M:$	0,9	0,85	0,5	0,1
------	-----	------	-----	-----

$P_x:$	300	400	500	505
--------	-----	-----	-----	-----

$P_y:$	300	400	500	505
--------	-----	-----	-----	-----

$i = 3$

$M:$	0,9	0,85	0,5
------	-----	------	-----

$P_x:$	300	400	500
--------	-----	-----	-----

$P_y:$	300	400	500
--------	-----	-----	-----

fim.

APÊNDICE B

AGRUPAMENTO DE MANCHAS

B.1 Introdução

Este apêndice apresenta um algoritmo que faz a separação de manchas, detectadas na *matriz-amostra*, em *grupos locais* e *grupo global*. O objetivo é fornecer subsídios para uma avaliação que esteja mais próxima da realidade. O resultado de saída desse algoritmo é usado na avaliação da *dispersão* e dos tipos de manchas (claras ou escuras) que constituem uma peça cerâmica.

B.2 Valores de Entrada

O agrupamento de manchas é efetuado considerando os vetores obtidos do Apêndice A. Esses vetores são em número de seis e têm seus elementos descritos aqui por conveniência.

- M_E : pertinência dos valores dos *pixels* de manchas escuras;
- P_{XE} : posição horizontal dos valores dos *pixels* manchas escuras;
- P_{YE} : posição vertical dos valores dos *pixels* manchas escuras;
- M_C : pertinência dos valores dos *pixels* manchas claras;
- P_{XC} : posição horizontal dos valores dos *pixels* manchas claras;
- P_{YC} : posição vertical dos valores dos *pixels* manchas claras.

É importante ressaltar que esses vetores tiveram vários valores de seus *pixels* descartados por pertencerem à uma mesma mancha, como descrito no Apêndice A.

O algoritmo proposto para separação dos grupos de manchas locais e global (definidos na subseção 4.4.1.1), por simplicidade, é mostrado para um tipo de mancha qualquer (manchas claras ou escuras). Com base nisto têm-se os seguintes vetores de entrada e seus elementos:

$$M = [\mu_1 \ \mu_2 \ \mu_3 \ \dots \ \mu_N]$$

$$P_x = [x_1 \ x_2 \ x_3 \ \dots \ x_N]$$

$$P_y = [y_1 \ y_2 \ y_3 \ \dots \ y_N]$$

B.3 Passos do Algoritmo

Passo 1:

Cálculo da distância entre dois pontos usando os vetores P_x e P_y . Monta-se uma matriz cujos elementos são as distâncias entre a i -ésima e a j -ésima mancha.

Para i de 1 até N faça {considera todos elementos nas linha}

Para j de $(i + 1)$ até N faça {considera todos elementos nas colunas acima da diagonal}

$$D(i, j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$

Fim do Para;

Fim do Para.

Passo 2:

Estrutura de repetição para separar os grupos locais e global.

1) Inicializações:

$r = 1;$ {estabelece os elementos do grupo global}

$s = 1;$ {conta o número de grupos locais}

$t = 1;$ {estabelece os elemento do s-ésimo grupo local}

2) Para $i = 1$ até N

Para $j = 1$ até N

Se $D(i, j) > 25$ Então faça

{Elementos do grupo global}

$$M_G(r) = \mu_i;$$

$$P_{xG}(r) = x_i;$$

$$P_{yG}(r) = y_i;$$

$$M_G(r+1) = \mu_j;$$

$$P_{xG}(r+1) = x_j;$$

$$P_{yG}(r+1) = y_j;$$

$$r = r + 2;$$

Senão faça

{Elementos do s-ésimo grupo local}

$$M_{Ls}(t) = \mu_i;$$

$$P_{xLs}(t) = x_i;$$

$$P_{yLs}(t) = y_i;$$

$$M_{Ls}(t+1) = \mu_j;$$

$$P_{xLs}(t+1) = x_j;$$

$$P_{yLs}(t+1) = y_j;$$

$$t = t+2;$$

{Estrutura de repetição para busca de outros elementos de mesmo grupo}

Para $k = j+1$ até N

Se $D(j, k) < 25$ Então faça

$$M_{Ls}(t) = \mu_j;$$

$$P_{xLs}(t) = x_j;$$

$$P_{yLs}(t) = y_j;$$

$$M_{Ls}(t+1) = \mu_k;$$

$$P_{xLs}(t+1) = x_k;$$

$$P_{yLs}(t+1) = y_k;$$

$$t = t+2;$$

Fim do Se;

Fim do Para;

$s = s + 1;$ {Índice de grupo local}

Fim do Se;

Fim do Para;

Fim do Para.

Fim do Algoritmo.

ELEMENTOS DE SAÍDA:

M_G : Vetor de pertinência para manchas globais;

P_{xG} : Vetor posição horizontal para manchas globais;

P_{yG} : Vetor posição vertical para manchas globais;

M_{Li} : i-ésimo vetor de pertinência para manchas locais;

P_{xLi} : i-ésimo vetor posição horizontal para manchas locais;

P_{yLi} : i-ésimo vetor posição vertical para manchas locais;